



T.C.
SAKARYA ÜNİVERSİTESİ
TIP FAKÜLTESİ

**KEMİK FRAKTÜRLERİNİN RADYOLOJİK TANISINDA
YAPAY ZEKA TABANLI KARAR DESTEK ALGORİTMASI
GELİŞTİRİLMESİ**

ZEHRA OTURAK

UZMANLIK TEZİ

RADYOLOJİ ANABİLİM DALI

DANIŞMAN
Doç. Dr. Onur TAYDAŞ

2024-SAKARYA

T.C.
SAKARYA ÜNİVERSİTESİ
TIP FAKÜLTESİ

**KEMİK FRAKTÜRLERİNİN RADYOLOJİK TANISINDA
YAPAY ZEKA TABANLI KARAR DESTEK ALGORİTMASI
GELİŞTİRİLMESİ**

ZEHRA OTURAK

UZMANLIK TEZİ

RADYOLOJİ ANABİLİM DALI

DANIŞMAN
Doç. Dr. Onur TAYDAŞ

2024-SAKARYA

ONAY

Kurum : Sakarya Üniversitesi/Tıp Fakültesi
Program türü : Uzmanlık Tezi
Anabilim Dalı :
Tez Sahibi :
Sınav Tarihi : **Saat:**
Tez Başlığı :

Bu çalışma, içerik ve kalite bakımından Uzmanlık Tezi olarak Oybirliği / Oyçokluğu ile kabul edilmiştir.

	Ünvan, Adı-Soyadı (Kurum adı)	İmza	Kabul/Red *
Danışman (Üye)			
Üye			
Üye			

* Red kararının gerekçesi onay sayfasının arkasında belirtilmelidir.

ONAY

“Bu tez .././202.. tarihinde yukarıdaki jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.”

.././202..
Tıp Fakültesi Dekanı

BEYAN

Bu tezin kendi çalışmam olduğunu, planlanmasından yazımına kadar hiçbir aşamasında etik dışı davranışımın olmadığını, tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları kaynaklar listesine aldığımı, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Bu araştırmaya T.C. Sakarya Üniversitesi Tıp Fakültesi Girişimsel Olmayan Araştırmalar Etik Kurulu'ndan E-71522473-050.01.04-241683-129 karar sayılı ve 02/05/2023 tarihli etik kurul onayı alınarak hazırlanmıştır.

Tarih:

23/07/2024

Dr. Zehra Oturak

TEŞEKKÜR

Asistanlığımın ilk gününden bugüne kadar bize yakın ilgi gösteren, hem eğitimimize çok önemli katkılar sunup hem de bize sosyal anlamda destek olan, sevincimizle sevinen, üzüntümüzle üzülen, heyecanımızla heyecanlanan, asistanı olmakla gururlandığımız, belki çok belli edemesek de çok sevdiğimiz ana bilim dalı başkanımız Prof. Dr. Mehmet Halil Öztürk'e,

Asistanlığa başladığım günden itibaren üzerimde emeği büyük olan her zaman her sorunuzda ulaşabildiğimiz ve bize güler yüzle yaklaşan, mesleki kazanımlarımda büyük pay sahibi hocalarım Prof. Dr. Yasemin Gündüz başta olmak üzere Doç. Dr. Alper Karacan'a ve Dr. Öğr. Üyesi Fuldem Mutlu'ya,

Hem tez sürecinde, hem bilimsel anlamda hem de girişimsel radyoloji alanında çalışırken her zaman bize destek olan her sorunuzda kolaylıkla ulaşabildiğimiz ve bize her zaman yardımcı olan Doç. Dr. Onur Taydaş'a,

Yine girişimsel radyoloji alanında çalışırken bana her zaman hem abilik hem hocalık yapan hocalarım Doç. Dr. Ömer Faruk Ateş ve Dr. Öğr. Üyesi Mustafa Özdemir'e,

Asistanlığımın ilk günlerinden itibaren bilgi ve tecrübelerini benimle paylaşan her sorunuzda sabırla bize yardımcı olan Dr. Öğr. Üyesi Laçın Tatlı Ayhan, Doç. Dr. Saliha Çıracı, Uzm. Dr. Yahya Yumlu, Uzm. Dr. Akif Ergüven, Uzm. Dr. Kıyasettin Asil, Uzm. Dr. Yakup Ersel Aksoy, Uzm. Dr. Özlem Kitiki Kaçira ve hem asistanlık sürecinde hem uzmanken beraber çalıştığımız kliniğimiz uzman doktorlarına,

Hayatımın her döneminde aklımda olacak anılar biriktirdiğimiz, beraber çalışıp beraber güldüğümüz meslek hayatımda tekrar beraber çalışmak istediğim ve sosyal hayatta zaten hep görüşeceğim başta canım dostum Zeynep Yıldız olmak üzere, benden önce eğitimini tamamlayan kıdemlilerim ve benden sonra eğitime başlayan sevgili asistan arkadaşlarıma,

Asistanlık sürecinde ve sosyal hayatta iyi niyetli tavrıyla her zaman bize yardımcı olan girişimsel radyoloji ünitesi sorumlu hemşiresi canım ablamız Fatma Alkan ve

Reyhan Demirtaş başta olmak üzere kliniğimizin tüm hemşireleri, teknisyenleri ve personellerine,

Hem her daim güleryüzleri ile sağladıkları motivasyon için hem de tezime teknik olarak katkıları için değerli dostlarımız Ahmed Cihad Genç ve Fevziye Türkoğlu Genç'e,

Bütün hayatım boyunca destekleriyle ve sevgileriyle koşulsuz her zaman yanımda olan annem Esra Kurt, babam Mehmet Kurt ve kardeşlerim Rumeysa ve Fatıma Kurt'a,

Beni her zaman destekleyen varlığıyla hayatıma anlam katan, iyi günde kötü günde yanımda olan biricik eşim Gökhan ve canımdan daha çok sevdiğim oğlum Ahmed Hamza'ya teşekkürlerimi sunarım.

Dr. Zehra Oturak

İÇİNDEKİLER

<u>BEYAN</u>	i
<u>TEŞEKKÜR</u>	ii
<u>İÇİNDEKİLER</u>	iv
<u>KISALTMA VE SİMGELER LİSTESİ</u>	vi
<u>TABLO LİSTESİ</u>	vii
<u>ŞEKİL LİSTESİ</u>	viii
<u>RESİM LİSTESİ</u>	ix
<u>ÖZET</u>	x
<u>ABSTRACT</u>	xi
<u>1. GİRİŞ VE AMAÇ</u>	1
<u>2. GENEL BİLGİLER</u>	4
<u>2.1. Kemik Kırıkları</u>	4
<u>2.1.1. Tanım ve epidemiyoloji</u>	4
<u>2.1.2. Patofizyoloji ve risk faktörleri</u>	5
<u>2.1.3. Kırık tipleri</u>	7
<u>2.1.3.1. Travmatik kırıklar</u>	8
<u>2.1.3.2. Avülsiyon kırıkları</u>	8
<u>2.1.3.3. Stres kırıkları</u>	9
<u>2.2. Yapay Zeka</u>	12
<u>2.3. Yapay Zekanın Tarihsel Gelişimi</u>	14
<u>2.4. Yapay Zeka ve Sağlık Alanındaki Uygulamalar</u>	16
<u>3. GEREÇ VE YÖNTEMLER</u>	18
<u>3.1. Araştırmanın Yeri ve Zamanı</u>	18
<u>3.1.1. Araştırmanın yeri</u>	18

<u>3.1.2. Araştırmanın zamanı</u>	18
<u>3.2. Araştırmanın Tipi</u>	18
<u>3.3. Araştırmanın Evreni ve Örneklemi</u>	18
<u>3.4. Veri Toplama Araçları ve Yöntemleri</u>	18
<u>3.4.1. Veri toplama araçları</u>	18
<u>3.4.2. Araştırmanın insan gücü</u>	18
<u>3.5. Araştırmanın Süreci</u>	19
<u>3.6. Etik Kurul Onayı ve İzinler</u>	19
<u>3.7. Araştırmanın Bütçesi</u>	19
<u>3.8. Araştırmanın Sınırlılıkları</u>	19
<u>3.9. İstatistiksel Analiz</u>	19
<u>4. BULGULAR</u>	21
<u>4.1. Yapay zeka modelinin oluşturulması</u>	24
<u>5. TARTIŞMA VE SONUÇ</u>	30
<u>6. KAYNAKLAR</u>	35
<u>7. EKLER</u>	41
<u>7.1. Ek-1: Etik Kurul Kararı:</u>	41
<u>ÖZGEÇMİŞ</u>	42

KISALTMA VE SİMGELER LİSTESİ

ABD: Amerika Birleşik Devletleri

BG: Bilgisayarla Görme

BT: Bilgisayarlı Tomografi

DDİ: Doğal Dil İşleme

DÖ: Derin Öğrenme

MÖ: Makine Öğrenimi

MRG: Manyetik Rezonans Görüntüleme

OPG: Osteoprotegerin

USG: Ultrasonografi

RANK: NF-KB reseptör aktivatörü

RANKL: NF-KB ligandının reseptör aktivatörü

YSA: Yapay Sinir Ağı

YZ: Yapay Zeka

TABLO LİSTESİ

<u>Tablo 2.1. Yorgunluk ve yetmezlik kırıkları arasındaki farkların özeti (Matcuk ve ark., 2016'dan kullanılmıştır)</u>	10
<u>Tablo 2.2. Stres kırıklarının görüntülenmesinde ortak bulgulara göre sık karşılaşılan ayırıcı tanılar (Matcuk ve ark., 2016'dan kullanılmıştır)</u>	11
<u>Tablo 2.3. Stres kırığı görüntülenmesinde modalite bazlı avantaj/ sınırlamalar (Matcuk ve ark., 2016'dan kullanılmıştır)</u>	12
<u>Tablo 2.4. Yapay zekanın alt alanları (Kaul ve ark., 2020'den kullanılmıştır)</u>	13
<u>Tablo 4.1. Araştırmaya dahil edilen hastaların demografik özellikleri</u>	21
<u>Tablo 4.2. Araştırmaya dahil edilen hastaların kırık lokalizasyonları ve kırık tipleri</u>	23
<u>Tablo 4.3. Fraktür olan ve olmayan iki gruba ait test veri setinin yapay zeka ile değerlendirilmesine ait sonuçlar</u>	29

ŞEKİL LİSTESİ

<u>Şekil 2.1. Kemik döngüsünde rol alan kök hücre ve üç ana kemik hücresi türü gösterilmiştir: osteoblastlar, osteositler ve osteoklastlar</u>	6
<u>Şekil 2.2. Osteoblastlar, osteositler ve osteoklastlar tarafından salgılanan moleküller, kemik oluşumu ve kemik emilimi dengesini korumak için parakrin bir şekilde birbirlerini etkiler. Osteoblastlar, RANKL eksprese ederek osteoklast oluşumunu aktive eder ve RANKL (NF-KB ligandının reseptör aktivatörü), OPG(osteoprotegerin) aracılığıyla osteoklast aktivitesini inhibe eder.</u>	7
<u>Şekil 2.3. Yapay Zekanın Kronolojik Tarihi (Arslan, 2020; McCarthy ve ark., 2006'dan değiştirilerek kullanılmıştır)</u>	15
<u>Şekil 2.4. Sağlık Hizmetlerinde Yapay Zeka Modellemeleri/ Algoritmaları (Çilhoroz ve Işık, 2021'den değiştirilerek kullanılmıştır).</u>	17
<u>Şekil 4.1. Araştırmaya dahil edilen hastaların cinsiyet dağılımı</u>	21
<u>Şekil 4.2. Araştırmaya dahil edilen hastaların yaş dağılımı</u>	22
<u>Şekil 4.3. Araştırmaya dahil edilen hastaların kırık lokalizasyonlarının dağılımı</u>	24
<u>Şekil 4.4. Araştırmaya dahil edilen hastaların kırık tiplerinin dağılımı</u>	24

RESİM LİSTESİ

<u>Resim 4.1. Herhangi bir görüntü ilemi yöntemi uygulanmamış direkt grafi örneği</u>	26
<u>Resim 4.2. “Gürültü ekleme” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği</u>	26
<u>Resim 4.3. “Bulanıklaştırma” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği</u>	27
<u>Resim 4.4. “Kırpma” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği</u>	27
<u>Resim 4.5. “Çevirme” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği</u>	28
<u>Resim 4.6. “Döndürme” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği</u>	28

ÖZET

GİRİŞ VE AMAÇ: Yaygın olan ve sıklığı artan kırık vakalarına zamanında doğru tanının konulabilmesi için destek sistemlerine ihtiyaç vardır. Bu araştırma da acil servise kırık şüphesi ile başvuran hastaların, direkt grafilerini hekimlerin değerlendirilme sürelerinin ve kırığı atlama riskinin düşürülebilmesi için yapay zeka tabanlı karar destek algoritmasının oluşturulması amaçlanmaktadır.

YÖNTEM: Araştırmaya 1040 fraktür grafisi ve 250 fraktür olmayan grafi dahil edildi. Bunlardan 832 fraktür grafisi ve 200 fraktür olmayan grafi eğitim datası olarak kullanılırken, 208 fraktür grafisi ve 50 fraktür olmayan grafi test datası olarak kullanıldı. Ham grafi imajlarına gürültü ekleme, bulanıklaştırma, kırma, çevirme ve döndürme gibi görüntü işleme teknikleri uygulanarak her imaj için 10 farklı görüntü elde edildi. Bu şekilde 10 320 direkt grafi kullanılarak transfer learning metodu ile makine öğrenimi gerçekleştirildi.

BULGULAR: Test setindeki 258 grafi, oluşturulan model ile tahmin edildi. Model kırığı olan hastaların %82'sini kırık olarak tahmin etmektedir (Duyarlılık). Sağlam olan hastaların %88'ini sağlam olarak tahmin etmektedir (Özgüllük). Modelin kırık olarak tahmin ettiği hastaların %97'si gerçekte kırıktır (Kesinlik). Modelin sağlam olarak tahmin ettiği hastaların %54'ü gerçekte sağlamdır (Negatif prediktif değer). Model sağlam hastaların %12'sini kırık olarak tahmin etmektedir (Yanlış pozitiflik oranı). Model kırık hastalarının %18'ini sağlam olarak tahmin etmektedir (Yanlış negatiflik oranı). Modelin tüm hastalar içinde doğru tahmin yapma sıklığı ise %83'tür (Doğruluk). Modelin F1 skoru 0,89'dur.

SONUÇ: Oluşturulan model verilerine göre özellikle %97 kesinlik ile hekimin kırık olduğunu düşündüğü vakalarda daha hızlı karar vermesini sağlayacaktır. Acil servislerde buna benzer modellerin kullanımı yanlış ve gecikmiş tanı sıklığını en aza indirecektir.

Anahtar Kelimeler: Direkt grafi, kırıklar, makine öğrenimi, yapay zeka

ABSTRACT

Development of an artificial intelligence-based decision support algorithm in the radiological diagnosis of bone fractures

INTRODUCTION AND AIM: Support systems are needed to ensure timely and accurate diagnosis of fracture cases, which are common and increasing in frequency. This research aims to create an artificial intelligence-based decision support algorithm to reduce the time taken for physicians to evaluate direct radiographs of patients who apply to the emergency department with suspected fractures and to reduce the risk of missing a fracture.

METHOD: 1040 fracture and 250 non-fracture radiographs were included in the study. Of these, 832 fracture radiographs and 200 non-fracture radiographs were used as training data, while 208 fracture radiographs and 50 non-fracture radiographs were used as test data. 10 different images were obtained for each image by applying image processing techniques such as adding noise, blurring, breaking, flipping and rotating to the raw radiograph images.

RESULTS: 258 graphs in the test set were predicted with the created model. The model predicts 82% of patients with fractures as fractures (Sensitivity). It predicts 88% of healthy patients as healthy (Specificity). 97% of patients that the model predicts to have a fracture actually have a fracture (Precision). 54% of the patients predicted by the model to be healthy are actually healthy (Negative predictive value). The model predicts 12% of healthy patients to have a fracture (False positive rate). The model predicts 18% of fracture patients as intact (False negative rate). The frequency of the model making correct predictions among all patients is 83%. The F1 score of the model is 0.89

CONCLUSION: According to the model data created, it will enable the physician to make faster decisions, especially in cases where he thinks there is a fracture, with 97% accuracy. The use of similar models in emergency departments will minimize the frequency of incorrect and delayed diagnosis.

Keywords: Plain radiography, fractures, machine learning, artificial intelligence

1. GİRİŞ VE AMAÇ

Kırık sıklığı farklı zamanlarda yapılmış araştırmalarda farklı ülkeler için sapmalar gösterebilmektedir. Amerika Birleşik Devletleri'nde (ABD) 100.000 kişide yıllık 1291 olan kırık insidansı, İsveç'te 1229, Birleşik Krallıkta 948 olarak tespit edilmiştir (Bergh ve ark., 2020; Curtis ve ark., 2016; Farr ve ark., 2017).

Nisan 2019 ile Nisan 2020 arasındaki bir yılda, Birleşik Krallık'ta acil servise akut kırık veya çıkık nedeniyle 1,2 milyon hasta başvurmuş olup bu veriler 2018 yılı verilerine göre %23 artış göstermiştir ve bu durum küresel düzeyde endişe yaratan bir halk sağlığı sorunu haline gelmiştir. Radyografilerde kırıkların atlanması veya gecikmiş tanısı %3 ile %10 arasında değişen yaygın bir tanı hatasıdır. Klinisyenin deneyimi azaldıkça kırık tanısında hata olma riski artmaktadır, ancak uzman görüşüne hızlı ve zamanında erişim yaygın olarak mevcut değildir (Kuo ve ark., 2022). Radyologlara açılan malpraktis davalarında ABD verilerine göre en sık neden atlanan meme kanseri tanısından sonra 2. sırada gelen atlanan ekstremitte kırıklarıdır. Gözden kaçan bazı kırıklar geriye dönüp bakıldığında algısal hatalarla ilişkili olabilse de, diğerleri yorumlayan radyoloğun kontrolü dışında kalan hız bağımlı hatalardır (Whang ve ark., 2013). Yaygın olarak görülen ve sıklığı artmakta olan kırık vakalarına zamanında ve doğru tanının konulabilmesi için destek sistemlerine ihtiyaç vardır.

İnsanlık, uzun yıllar boyunca zamandan ve iş gücünden kazanç sağlamaya çalışmış ve bu yüzden bir takım işleri otomatik olarak yapabilen akıllı makinelere ilgi göstermiştir (Furkan ve ark., 2023). Bu ilginin beraberindeki değişimler sonucunda son dönemlerde adından sıkça söz ettiren Yapay Zekâ (YZ) adı verilen kavram ortaya çıkmıştır. Bu yeni kavram, sağlık alanının da içinde bulunduğu pek çok alanda meselelerin çözülmesine yönelik; karar verme, problem çözme, olası sorunları öngörme ve prognoz hakkında bilgi verme gibi insan zekasının görevlerini yerine getirebilen; teorileri, metodları ve uygulamaları kapsayan bilgisayar sistemlerinin geliştirilmesidir (Talan ve Kalıncara, 2023). YZ tabanlı araçlar; risk derecelendirmesi, doğru tanı ve tedavi yöntemi belirlenmesi gibi sağlıkta çeşitli alanlarda kullanılmaktadır. Bu aşamalarda oluşabilecek belirsizliğin birçok tıbbi karar üzerine etkisi göz önüne alındığında, YZ çözümleri sağlık hizmetlerinin

iyileştirilmesine anlamlı şekilde katkıda bulunabilir (Houthoof ve ark., 2015; Kuo ve ark., 2015; Mokhtar ve ark., 2015). Ayrıca YZ'nin sağlık alanında kullanılmaya başlanması ile özellikle acil servislerde, hastaların triajında ve tedaviye yanıt verme süreçlerinde önemli kazanımlar elde edilmeye başlanmıştır. Her geçen gün tüm dünyada tıbbi bakım arayan hasta sayısının artması sonucu kalabalıklaşan acil servisler; hastaları değerlendirmek, yönetmek, hızlı ve doğru yönlendirmek için verimli bir sistem kullanmak zorundadır. (Christ ve ark., 2010; Durani ve ark., 2009; Fernandes ve ark., 2005). Acil servislerdeki her geçen gün artan yoğunluk ve iş yükü tüm dünyadaki gibi Türkiye'de de sağlık kuruluşlarının en önemli sorunlarından. Literatürde yer alan çoğu çalışmada, bu yoğunluğun kriz derecesine ulaştığı, bunun da halk sağlığı ve hasta güvenliği bakımından tehdit unsuru oluşturduğu bildirilmiştir (Cowan ve Trzeciak, 2005) Acil servislerdeki yoğunluğun sebepleri arasında artan hasta sayısı, tanısal tetkiklerdeki gecikmeler, eskiye kıyasla dosya işlemlerinde artışlar, sorumlu konsültan hekimlerin geciken geribildirimleri gibi nedenler sayılmaktadır (Trzeciak ve Rivers, 2003). Teknolojinin hızla ilerlemesi ile, acil servislerde fazla sayıdaki hasta, radyolojik görüntüleme hizmeti, laboratuvar testleri gibi diğer servislerce sunulan hizmetlerden yararlanmaktadır. Özellikle eğitim hastanelerinde bu servisler yoğunluğa bağlı daha yavaş hizmet verdiğinden hastaların acil serviste kalış sürelerini uzatmaktadır (Fatovich ve Hirsch, 2003) Bu süreyi kısaltarak mevcut iş yükünü azaltmak adına atılan adımlar ve yapılan yapay zeka çalışmaları umut vadetmektedir. Teşhis sürecini kolaylaştırma ve hızlandırma yönünde çalışmalar devam etmektedir. Özellikle acil servis hizmetleri gibi hızın önemli olduğu kliniklerde yapay zeka destekli uygulamaların kullanımı; doğru ve zamanında triyajın yapılmasını sağlayacağından maliyet, etkinlik ve hasta bakım kalitesine direkt etkilidir. Bu nedenle, YZ alanında geliştirilen uygulamaların özellikle acil servis hizmetlerinde sağlayacağı iyileşme potansiyeli son derece önemlidir (Berlyand ve ark., 2018).

Hasta yönetiminde gecikmelere ve hatalara neden olabilecek uygunsuz triyaj yönteminin uygulanmasının önüne geçebilmek için YZ tabanlı sistemlerin gelişmesi günümüz sağlık sisteminde ciddi faydalar sağlayabilir. (Mathews ve ark., 2018; Mohr ve ark., 2020; Yurkova ve Wolf, 2011). Öyle ki herhangi bir araç, uzman girdisi gerekliliğini ortadan kaldırabilirse; hastaların acil müdahale ekipleri

tarafından deęerlendirilmesi kolaylařtırılacaktır (Christ ve ark., 2016; Hossein Nejad ve ark., 2016) Hatalı veya gecikmiř tanıların ortaya ıkması, acil tıpta nemli bir endiře kaynaęıdır. Kemik kırıkları, acil servise bařvuru nedenlerinin nemli bir kısmını oluřturmakta olup hayati tehlike arz eden birok hastalıęın habercisi olabilmektedir. Kemik kırıęı varlıęının vakit kaybetmeksizin belirlenip hasta triajının buna gre yapılması ve beraberinde srecin hastane bilgi sistemleri ile btnleřtirerek karar destek yazılımlarına devredilmesi, yenilenen teknolojinin sonucu olarak grlmřtr. zellikle acil servise kırık řphesi ile bařvuran hastaların direkt grafilerinin hekimler tarafından deęerlendirilme srelerinin ve kırık tanısının atlama riskinin dřrlebilmesi iin yapay zeka tabanlı karar destek algoritmasının oluřturulması amalanmaktadır.

2. GENEL BİLGİLER

2.1. Kemik Kırıkları

2.1.1. Tanım ve epidemiyoloji

Kemik kırığı; kemikteki havers kanalları, damar yapıları, periost ve periost çevresindeki dokuların, kemiğin dayanma gücünü aşan mekanik bir kuvvet nedeniyle hasarlandığı, kemik dokuda nekroza neden olan yaralanma olarak tanımlanmaktadır (Tanrikulu ve Gönen, 2017).

Kırık insidansı için farklı ülkelerden farklı veriler mevcuttur. Amerika Birleşik Devletleri'nde 2009-2011 yılları arasındaki verilerin değerlendirildiği bir kohort araştırmasında kırık insidansı 100.000 kişide yıllık 2704 olarak tespit edilmiştir (Amin ve ark., 2014). Aynı veri tabanı ile yapılan başka bir çalışmada 18-49 yaş arası erişkinlerde kırık insidansı 100.000 kişide yıllık 1291 olarak tespit edilmiştir (Farr ve ark., 2017). Birleşik Krallıkta 1988-2012 yılları arasındaki verilerin incelendiği bir çalışmada, 18-49 yaş arasındaki erkeklerde yıllık kırık insidansı 100.000 kişide 948, 18-49 yaş arası kadınlarda yıllık 100.000 kişide 543 olarak tespit edilmiştir (Curtis ve ark., 2016) İsveç'te yapılan prospektif bir kohort araştırmasında 2015-2018 yılları arasındaki 4 yılda veri toplanmış ve kırık insidansı 100.000 kişide yıllık 1229 olarak tespit edilmiştir (Bergh ve ark., 2020). Literatürde, ülkemizde herhangi bir zamana ait kırık insidansı verisine rastlanmamıştır.

Ülkemizde hastanelerde tespit edilen kırık hastaları üzerinden yapılan araştırma bulgularına göre kırık tespit edilen hastaların çoğunluğu erkek cinsiyette, 18-45 yaş aralığındadır. Kırıklar çoğunlukla düşme sonucu oluşmuştur. Kırığı olan hastalar çoğunlukla hastane yatışı yapılarak tedavi edilmektedir. En sık kırılan kemikler humerus, femur, tibia, fibula, ulna ve radiusdur (Nişancı, 2019; Pamuk, 2019).

Türkiye'de yine hastane tabanlı ancak çocuk yaş grubunda meydana gelen araştırmalar incelendiğinde, 6 yaş altında kırık sayılarının cinsiyete göre dağılımı benzerken 6 yaş üstünde erkek cinsiyetin baskınlığı ödn plana çıkmakta, 12-16 yaşlar arasındaki oran 2:1'e kadar çıkmaktadır. Çocuk yaş grubunda kırıklar en sık ev ve sokak ortamında gerçekleşirken, en sık neden düşmedir. Kırıklar en sık yaz mevsiminde görülmekte ve en sık distal radius bölgesinde kırık meydana gelmektedir (Tarğal ve ark., 2018; Zümrüt, 2014).

Farklı ülkelerde yapılan kohort arařtırmalarının verilerine göre 50 yařına kadar erkeklerde kırık insidansı kadınlara göre daha yüksektir. Ancak 50 yařından sonra kadınlarda kırık insidansı erkekleri geçmektedir (Bergh ve ark., 2020; Curtis ve ark., 2016; Farr ve ark., 2017).


İsveç'te yapılan kohort arařtırması verilerine göre ortalama kırık yaşı 57,9 yıl (16-105 yıl aralığı) idi ve kırıkların %64,5'i kadınlarda meydana geldi. En sık kırık görülen beř bölgede kırığı olanların yař ortalamaları; proksimal femur kırıkları için 81,1, proksimal humerus kırıkları için 66,6, distal radius kırıkları için 59,8, ayak bileğı kırıkları için 52,8 ve metakarpal kırıklar için 40,1 yıldır. Proksimal femur kırığı ileri yařla en yakından iliřkili olan kırıktır. Proksimal femur kırığına sahip bireylerin %97,8'i 50 yař ve üzeri, %77,2'si ise 75 yař ve üzeriydi (Bergh ve ark., 2020). Birleřik Krallık'ta yapılan kohortta erkeklerde, 18 yařından itibaren 60-64 yař grubuna kadar yař arttıkça kırık insidansının kademeli olarak azaldığı, 65 yařından sonra plato yaptığı ve 75 yařından sonra artmaya bařladığı tespit edilmiřtir. Kadınlarda ise 18 yařından itibaren 50 yařına kadar kırık insidansı çok yavař artarken, 50 yařından sonra ciddi artıřlar göstermektedir. Etnik kökene göre incelendiğinde düşük kırık oranları her iki cinsiyetten siyahi bireylerde gözlemlendi. En belirgin fark ise frajilite kırıklarında görüldü. Beyaz kadınlarda frajilite kırığı insidansı siyah kadınlara göre 4,7 kat, beyaz erkeklerde ise siyah erkeklere göre 2,7 kat daha fazlaydı (Curtis ve ark., 2016).

Nisan 2019 ile Nisan 2020 arasındaki bir yılda, Birleřik Krallık'ta acil servise akut kırık veya çıkık nedeniyle 1,2 milyon hasta bařvurdu; bu veriler önceki yıla göre %23 artıř gösterdi (Kuo ve ark., 2022)


2.1.2. Patofizyoloji ve risk faktörleri

Wolff yasası, normal kemięe kuvvet uygulandıęında kemięin daha güçlü olmak için kendini yeniden řekillendirerek tepki vereceğini belirtir. Kemik döngüsünde üç ana kemik hücresi (řekil 2.1) türü rol oynar: osteoblastlar, osteositler ve osteoklastlar (Yavuz ve Sözen, 2013). Osteositler kemikteki en yaygın hücrelerdir ve hem osteoklastik hem de osteoblastik fonksiyonların ana orkestrator olarak kabul edilirler (Moreira ve Bilezikian, 2017). Osteositler, yoğun bir dendritik aę aracılıęıyla biyomekanik strese yanıt verir. Bu hücreler osteoklast ve osteoblast aktivitesini düzenleyen aracıları salgılar. Kemięe belli periyotlarla uygulanan kuvvetin, osteosit

sinyallerinin normal dendritik süreçlerinin bozulmasına neden olabileceği ve dolayısıyla fizyolojik onarım mekanizmalarını engelleyeceği bilinmektedir. Tekrarlayan yüklenme ise, osteoklastların, osteoblastların yeni kemik oluşturmaktan daha hızlı şekilde kemikte erimeyi (rezorpsiyon) uyaracaktır. Normal yeniden yapılanma döngüsü 3 ila 4 ay sürecektir (May ve Marappa-Ganeshan, 2023). Kemik, hasarlı kemiğin yerini alan ve kemik oluşturan osteoblastların ve kemiği rezorbe eden osteoklastların dengede devam eden çalışmalarıyla mekanik yüke göre şekillenir. Kemikte ömür boyunca dinamik olarak yeniden şekillenme (remodelling) devam eder. Kemiğin yeniden yapılanmasının dengeli bir şekilde devam etmesi, kemik ağırlığının ve iskelet bütünlüğünün korunması için gereklidir. Kemik yeniden yapılanmasının karmaşık süreci, bir takım endojen ve ekzojen faktörler tarafından düzenlenir. Öncelikle doğrudan osteoblastlara ve osteoklast öncüllerine etki eden RANK/RANKL/OPG sistemi tarafından düzenlenmektedir (Şekil 2.1). Osteoblastlar tarafından eksprese edilen RANKL (NF-KB ligandının reseptör aktivatörü), osteoklastogenezi indükleyen osteoklast öncülleri üzerindeki RANK (NF-KB reseptör aktivatörü) reseptörüne bağlanır. Osteoblast tarafından üretilen OPG, RANKL ın etkilerini bloke (Şekil 2.2) eden bir tuzak reseptörü gibi işlev görür (Hsu ve ark., 1999; Suda ve ark., 1999)



Şekil 2.1. Kemik döngüsünde rol alan kök hücre ve üç ana kemik hücresi türü gösterilmiştir: osteoblastlar, osteositler ve osteoklastlar



Şekil 2.2. Osteoblastlar, osteositler ve osteoklastlar tarafından salgılanan moleküller, kemik oluşumu ve kemik emilimi dengesini korumak için parakrin bir şekilde birbirlerini etkiler. Osteoblastlar, RANKL eksprese ederek osteoklast oluşumunu aktive eder ve RANKL (NF-KB ligandının reseptör aktivatörü), OPG(osteoprotegerin) aracılığıyla osteoklast aktivitesini inhibe eder.

Kemiğin yeniden şekillenmesini düzenleyen birçok lokal ve sistemik faktör ($TGF-\beta$, kemik morfojenik proteinleri; $TNF-\alpha$, $IL-1\beta$ ve $IL-6$ gibi sitokinler; PTH, 1,25-Vit D3 ve östrojen gibi hormonlar), esas olarak osteoblastlar üzerindeki RANK/RANKL/OPG sistemini etkileyerek sinyal verir ve böylece sistemi dengede tutar (Crockett ve ark., 2011). Bu endojen belirleyicilere ek olarak mekanik yükleme ve beslenme gibi ekzojen faktörler de söz konusudur. Osteositler, nitrik oksit ve prostaglandinler dahil olmak üzere osteo-anabolik sinyallerin indüksiyonu yoluyla mekanik uyarıyı algılar ve yanıt verir (Robling ve ark., 2006). Kalsiyum ve D vitamini, kemik mimarisinde hayati işlevlere sahip olan temel bileşenlerdir (Gennari, 2001). Kemiğin yeniden şekillenmesindeki dengesizlikler, osteosklerozda görüldüğü gibi anormal derecede fazla kemik yapımına yol açarak veya osteoporozda gözlemlendiği gibi kemik kaybıyla sonuçlanan kemik yıkımının artması yoluyla kemik metabolizmasını bozabilir.

2.1.3. Kırık tipleri

Kırıkların tiplendirilmesinde çok sayıda sınıflandırma mevcut olup genel olarak; oluşum şekline göre sınıflandırıldığında; doğrudan travmaya bağlı oluşan darbe

kırıkları, çekiş kuvvetlerine bağlı oluşan avülsiyon kırıkları ve stres kırıkları olarak gruplandırılabilir (Cocco ve ark., 2022).

2.1.3.1. Travmatik kırıklar

Darbe kırıkları (impaksiyon kırığı) her yaştan bireyde ortaya çıkabilir ve bunların şekli ile anatomik konumu çeşitli faktörlere (bireysel kemik kalitesi ve travma dinamikleri) bağlıdır. Örneğin yaşlı kişilerde osteoporoz ve vitamin D eksikliği gibi kemik dokusunun direncini etkileyen patolojik durumlar nedeniyle küçük bir travma sonrasında da darbe kırığı meydana gelebilir.

2.1.3.2. Avülsiyon kırıkları

Avülsiyon kırıkları, çekme kuvvetinin neden olduğu kuvvet ile tendon veya bağların yapışma yerinden kortikal kemiğin dekolmanıdır. Avülsiyon kırıkları yumuşak dokunun kemiğe tutunduğu herhangi bir bölgede (ligament, tendon, tendon kılıfları, eklem kapsülü, labrum, retinakulum, menisküs) meydana gelebilir (Bianchi, 2020; McCoy ve Nelson, 2023). Avülsiyon kırıklarının en sık nedeni akut travmalardır. Bu yüksek ve düşük enerjili mekanizmaların tanımlandığı doğrudan veya dolaylı travmalar olabilir (McCoy ve Nelson, 2023). Çoğunlukla akut hadise sonrası yumuşak dokunun kemiğe ani çekme kuvveti uygulamasıyla oluşurken, nadiren kronik tekrarlayan avulsif streslerin kemiği yumuşak doku tarafından çekmesinden de kaynaklanabilir (McCoy ve Nelson 2023). Daha az sıklıkla, avülsiyon kırıkları cerrahi bir işlemin komplikasyonu veya genetik bozukluk, enfeksiyon veya neoplazma gibi patolojik bir durumun sonucu olarak da olabilir. Avülsiyon kırıklarının iki tipi vardır: akut ve kronik kırıklar. (Choi ve ark., 2021). Akut avülsiyon yaralanmaları kas-tendinöz ünitenin ani, kuvvetli ve dengesiz hareketinden kaynaklanır. Kronik yaralanmalar ise tekrarlayıcı kuvvetlerden kaynaklanır (Squires ve ark., 2001). Bazı anatomik bölgelerde avülsiyon kırıkları daha yaygın olabilir (Weintraub ve ark., 2020). Avülsiyon kırıklarının en sık görülen anatomik yerleri sırasıyla femurun büyük ve küçük trokanteri, humerus başının büyük tüberositası, distal humerusun medial epikondili, üst ve alt anterior iliak krestler, tibial tüberositas, iskiyal tüberositas ve beşinci metatarsal kemiğin tabanıdır (Hoffman ve ark., 2015). Epidemiyolojik veriler anatomik lokalizasyona ve yaşa göre değişkenlik gösterir. Avülsiyon kırıkları apofizlerinin zayıflığı nedeniyle kemik gelişimi tamamlanmamış pediatrik popülasyonda daha sık meydana gelse de, osteoporotik

yetişkinlerde de görülebilir (Schiller ve ark., 2017). Ergenlerde ve çocuklarda en sık görülen avülsiyon yaralanmaları pelvis ve diz bölgesindedir. Ayrıca yetişkinlerde, altta yatan dejenerasyon veya tendinozis nedeniyle tendon içinde de avülsiyon yaralanmaları sık görülür (Choi ve ark., 2021). Avülsiyon kırıkları sıklıkla eklem komşuluğunda, göreceli olarak yakın bir anatomik boşlukta bulunan çok sayıda destekleyici kemik, tendinöz ve kapsülogamentöz yapı nedeniyle veya apofizyal miyotendinöz bağlanma bölgelerinde meydana gelir (McCoy ve Nelson, 2023). Avülsiyon kırıklarının bazı türleri daha yaygın olsada klinik olarak anlamlı olduğu için önemli olan nadir etkilenen bölgelerde vardır. Bu yaralanmaların tanınması önemlidir çünkü sıklıkla eşlik eden diğer yumuşak doku veya osteokartilajinöz yaralanmalarla ilişkilidir veya eklem instabilitesine işaret edebilir. Avülsiyon yaralanmasını teşhis etmek için radyografi ilk görüntüleme yöntemidir, ancak arada kalınan vakalarda, etkilenen komşu yapıları, eklem ile ilişkisini ve yumuşak doku değişikliklerini tam olarak belirlemede, enfeksiyon neoplazm gibi durumları taklit ettiğinde ayırıcı tanıyı yapabilmek adına ileri görüntüleme yöntemlerine ihtiyaç duyulabilir (Choi ve ark., 2021). Avülsiyon kırıkları için, kırığın ve sekonder belirtilerinin görüntülenmesi zor olduğundan yapay zeka programlarına tanıtılması da genellikle zordur, bu da tespitini kolaylaştırmak ve yapay zeka programlarını bu konuda daha etkin hale getirebilmek için yapay zekaya yeterli sayıda etiketli numunenin tanıtılmasını ve bu konuda daha fazla çalışma yapılmasını gerektirmektedir (Ren ve Yi, 2022).

2.1.3.3. Stres kırıkları

Stres kırıkları kemik kuvveti ile kemiğe uygulanan mekanik yük arasındaki dengesizliği yansıtır (May ve Marappa-Ganeshan, 2023). Stres kırıkları sağlıklı kemiğe tekrarlayan anormal yük uygulanmasıyla ilişkili yorgunluk kırıkları ve patolojik/zayıflamış kemiğe normal yük uygulanmasından kaynaklanan yetersizlik kırıkları olarak alt gruplandırılabilir (Hoffman ve ark., 2015). Stres kırığı, etkilenen kemik matriksinin altta yatan durumuna göre kategorize edilir ve yorgunluk (normal kemik) veya yetersizlik (osteopenik kemik) kırığını içerir (Matcuk ve ark., 2016). Genellikle fiziksel aktivitenin sıklığı veya derecesi önemli ölçüde arttığında ortaya çıkarlar. Vücut artan aktiviteye yeterince hızlı uyum sağlayamadığından, kemikte mikro hasara ve kırılmaya neden olur. Kırığın gelişimine katkıda bulunan endojen ve

ekzojen faktörler vardır. (McCormick ve ark., 2012) Endojen faktörler arasında zayıf fiziksel kondisyon, kadın cinsiyet, hormonal bozukluk, adet düzensizliği, zayıf kemik yoğunluğu, azalmış kas kütlesi, genu valgum dizler ve kısa bacak yer alır. Egzojen faktörler arasında koşma, atlama, fiziksel aktivitede ani artış, Ca ve D vitamini eksikliği ve sigara yer alır. (McCormick ve ark., 2012). En yaygın risk faktörü aktivitede ani artıştır. Alt ekstremiteler en çok etkilenen bölgedir (%8-95); üst ekstremiteler %10'undan azını oluşturur (Abbott ve ark., 2020; Matcuk ve ark., 2016). Prevalans sırası tibia (%49), tarsal kemikler (%25), metatarslar (%9), femur ve fibuladır (Abbott ve ark., 2020) Ulna üst ekstremitelerde en çok etkilenen kemiktir. Nörolojik bozuklukları olan osteoporotik yaşlı hastalarda en çok etkilenen anatomik bölgeler sırasıyla pelvis, sakrum ve femur boynudur (Tablo 2.1) (Kozaci ve ark., 2017; Matcuk ve ark., 2016). Kalça veya dizdeki subkondral yetmezlik kırıkları acil durumlarda ortaya çıkabilecek akut ağrıya neden olabilir.

Tablo 2.1. Yorgunluk ve yetmezlik kırıkları arasındaki farkların özeti (Matcuk ve ark., 2016'dan kullanılmıştır)

	Yorgunluk- Stres Kırıkları	Yetmezlik Kırıkları
Tanım	Normal Kemik üzerindeki anormal kronik tekrarlayan stresten kaynaklanan kırık	Anormal derecede zayıflamış kemikte normal strese bağlı kırık
Epidemiyoloji	Genç, sporcular Kadınlar > Erkekler	Yaşlı, düşük vücut kitle indeksi Dişiler > Erkekler
Patofizyoloji	Anormal yük yeniden şekillenmeye yol açar, rezorpsiyon yenilenmeden büyük olduğunda kırık meydana gelir	Zayıflamış kemikte normal yük (osteopeni veya metabolik kemik hastalığı)
Sık etkilenen anatomik lokalizasyonlar	Tibia, fibula, metatarslar, femur boynu, pubik ramus, kalkaneus ve naviküler	Sakrum, pubik ramus, süperior asetabulum, femur başı, medial femoral kondil

Stres kırıklarının değerlendirilmesine yönelik görüntüleme önerileri, başlangıçta düz radyografilerin ardından, gerekirse bilgisayarlı tomografi (BT) ve kemik sintigrafisine tercih edilen manyetik rezonans görüntülemeyi (MRG) içerir. Radyografiler ilk seçenek yöntemdir ve kırık gelişmeden önceki öncü bulguları olan lineer skleroz ve periosteal reaksiyonu ortaya çıkarabilir. Radyografiler erken dönem

stres kırığını göstermede yetersizdir, özellikle osteopeni durumunda tanı koymak zordur. Stres kırığı olan alanda ilk olarak: hafif dereceli lineer skleroz (çoğunlukla majör trabeküllere dik), fokal endosteal ve periosteal reaksiyonun eşlik ettiği kortekse dik uzanımlı kırık hattı şeklinde ortaya çıkar (Daffner ve Pavlov, 1992). Bilgisayarlı tomografi (BT), reformat görüntülerin de oluşturulmasıyla uzunlamasına kırık hatlarının belirlenmesinde ek kolaylık sağlar. Özellikle osteoid osteoma gibi sık karışabilecek lezyonlardan ayırıcı tanı yapılmasında BT'nin yeri önemlidir (Matcuk et al. 2016; Tablo 2.2). Kesitsel BT, osteoid osteomanın merkezi düşük dansiteli nidusunu ortaya çıkarırken, kırıkta merkezi nidusun olmadığı lineer kırık hattı olacaktır (Sofka, 2006). MRG ise özellikle erken dönemde tanının konulmasında son derece duyarlıdır (duyarlılık %100, özgüllük %85), ancak tipik olarak ikinci basamak bir yöntem olup radyografiler normal olduğunda, ağrının etiyolojisi bilinmediğinde veya kesin tanı gerektiren durumlarda elde edilir (Mueller ve ark., 2014). MRG, periosteal ödemden kemik iliğine ve intrakortikal sinyal anormalliğine kadar değişen bulguları erken dönemde dahi kolaylıkla gösterebildiğinden tanıda oldukça duyarlıdır. Ultrason, stres kırıklarının değerlendirilmesinde daha kolay ulaşılabilir ve ucuz olmasının yanında yalnızca yüzeysel kemiklerin değerlendirilmesi ile sınırlıdır (Sofka, 2006). Kemik sintigrafisi (teknetyum-99m) kemiğin yeniden şekillenmesinin arttığı durumlara duyarlıdır ve semptomların başlamasından 3 ila 5 gün sonra bile kırık belirtilerini gösterebilir (Moreira ve Bilezikian, 2017). Bu yöntem, anormal metabolik kemik aktivitesinin tespit edilmesindeki hassasiyeti açısından mükemmeldir; ancak, asemptomatik bölgelerde %40'a varan oranda özgüllüğü düşük ve acil şartlarda kullanıma uygun değildir (Joshi ve ark., 2012; Matcuk ve ark., 2016; Tablo 2.3)

Tablo 2.2. Stres kırıklarının görüntülemesinde ortak bulgulara göre sık karşılaşılan ayırıcı tanıları (Matcuk ve ark., 2016'dan kullanılmıştır)

Bulgular	Ayırıcı Tanı
Fokal Kortikal Kalınlaşma	Normal Varyant, osteoid osteoma, Kronik Osteomyelit/ Brodie apsesi, stres yüklenmesi (artroplastiler)
Periost Reaksiyonu	Enfeksiyon, yüzey osteosarkomu, hipertrofik osteoartropati
Lineer sinyal artışı	Normal anatomik yapı olan besleyici vaskülerler, osteomalazi

Skleroz	Osteitis kondensans ilii, osteitis pubi, kronik osteomyelit
Kemik iliği Ödemi	Geçici kemik iliği ödemi sendromu, avasküler nekroz, osteomyelit, tümör

Tablo 2.3. Stres kırığı görüntülenmesinde modalite bazlı avantaj/ sınırlamalar (Matcuk ve ark., 2016'dan kullanılmıştır)

Görüntüleme Yöntemi	Bulgular ve avantajlar/ sınırlamalar
Radyografiler	Lineer skleroz, çoğunlukla majör trabekülkire dik Fokal endosteal/ periosteal reaksiyon ve kortekste kırılma
MR	Tüm sekanslarda lineer hipointens kırık hattı Komşu kemik iliğinde ve yumuşak dokuda ödem Pahalı, arada kalınan durumlarda ve ayırıcı tanıda kullanılabilir <i>Sensitivite %100, Spesifite %85</i>
BT	Kortekse paralel seyirli kırık hattını tanımlamada ideal Kortekse dik seyirli olan stres kırıklarının değerlendirmesinde gözden kaçabilir
Ultrason	Kırığa komşu kemikte hipoekoik kallus formasyonu Kırık olan kortekste basamaklanma Yüzeysel kemikleri değerlendirmede Ucuz, kolay ulaşılabilir
Kemik Taraması	Kronik dönemde dahi hassas Yanlış pozitiflik oranı yüksek, anatomik lokalizasyonu düşük Acil şartlara uygun değil

2.2. Yapay Zeka

Yapay Zeka (YZ), çözülmesi için insan zekası gereken problemlerin, insanlar tarafından bilgisayarlara ve makinalara belirli algoritmaların belirli yöntemler uygulanarak çözülmesi şeklinde tanımlanır (Hashimoto et al., 2018). Son yıllarda YZ, hızla ilerleyerek birçok mühendislik ve sağlık alanında kullanılmaya başlanmıştır (Ramesh ve ark., 2004). Yapay Sinir Ağlarını açıklamak için insan

beyninde öğrenmenin mekanizmasından örnek vermek gerekir. Nöronlar birden fazla sayıda girdi alır ve tek bir çıktı oluşturur. Her bir bağlantı için çıktının önemine göre bir ağırlık oluşturulur. Sinir ağı, bilinen girdilere göre bir çıktı tahmini oluşturur ve gerçek çıktı ile tahmin edilen çıktıyı karşılaştırır. Çıktıları ağırlıklandırmak için hata olup olmadığı değerlendirilir. Nihayetinde hatasız cevap üreten bağlantılar güçlendirilirken, hatalı cevaplar zayıflatılır (Furkan ve ark., 2023). Yapay zekada makine öğrenmesi (MÖ), derin öğrenme (DÖ) ve bilgisayarlı görme gibi tıptaki uzmanlıklara benzer birçok alt alan vardır (Kaul ve ark., 2020; Tablo 4). Makine öğreniminin temel özelliği verilerin sınıflandırılmasına dayanan problem çözme tekniğidir. Yapay zeka alanında, algoritmaların verilerden öğrenmesine olanak tanıyan, açık programlamaya ihtiyaç duymadan kendi performanslarını yinelemeli olarak artıran bir grup tekniği ifade eden bir terimdir (Furkan ve ark., 2023; Kuo ve ark., 2022). MÖ, insan beynine benzer şekilde kendi kendine öğrenerek karar verebilen, yapay sinir ağı (YSA) oluşturmaya yönelik algoritmalarından oluşan, daha yaygın olarak kullanılan DÖ olarak bilinen alana doğru evrilmiştir (Greenhill ve Edmunds, 2020). Derin öğrenme, genellikle makine öğrenimi ile birbirinin yerine kullanılan bir terimdir ancak herhangi bir girdiden yüksek düzeyde bilgi çıkarmak için birden fazla işlem katmanı kullanan algoritmaları ifade eder (Kuo ve ark., 2022). Derin öğrenmede, bir girdi verildiğinde en iyi sonucu (veya çıktıyı) vermek için girdi, bir sinir ağı tarafından öğrenilir. Sinir ağları tipik olarak birçok doğrusal olmayan iç içe geçmiş ilişki yoluyla bağlanan birçok katmandan oluşur. Tüm bu katmanları inceleyip aralarındaki ilişkileri anlatmak istesek bile, sinir ağının bu karara nasıl vardığını tam olarak anlamak mümkün değildir. Bu nedenle derin öğrenme genellikle bir 'kara kutu' olarak kabul edilir. Çeşitli uygulama alanlarında, bu kara kutuların bir şekilde yanlı (bias) olabileceği ve bu tür yanlılıkların gözden kaçabileceği endişesi vardır (van der Velden ve ark., 2022).

Tablo 2.4. Yapay zekanın alt alanları (Kaul ve ark., 2020'den kullanılmıştır)

	Yapay Zekanın Alt Alanları
Makine Öğrenimi (MÖ)	Model tanımlama ve analizi; makinelerin sağlanan veri setlerinden elde edilen deneyimlerle gelişmesi
Derin Öğrenme (DÖ)	Makinelerin kendi başına öğrenip karar vermesini sağlayan çok


	katmanlı sinir ağlarından oluşur
Doğal Dil İşleme (DDİ)	Bilgisayarların insan dilinden veri elde etmesi ve kararlar alması
Bilgisayarla Görme (BG)	Bilgisayarın bir dizi görüntü veya videodan bilgi elde etmesi

Günümüzde, yapay zekânın (YZ) kullanım alanları her geçen gün gelişen teknolojiyle beraber genişlemekte olup bu alandaki çalışmalara ihtiyaç da artmaktadır. Özellikle görüntü işleme alanında yapay zekânın alt disiplinlerinden biri olan tıbbi görüntü formatlarının dijitalleşmesi ile yapay zekânın sağlık alanında kullanımı oldukça dikkat çekici konular arasında yer almaktadır ve bu konuda yapılan çalışmalar da gittikçe artmaktadır (Atlan ve Pençe, 2021). YZ tabanlı uygulamalar; risk belirlenmesi, tanı ve tedavi seçimi gibi tıpta çeşitli alanlarda kullanılmaktadır. Son yıllarda tıbbi bakım arayan hasta sayısının artması nedeniyle özellikle kalabalık acil servisler; hastaları değerlendirmek, yönetmek ve öncelikleri ayırt etmek için verimli bir sistem kullanmak zorundadır (Christ ve ark., 2010; Durani ve ark., 2009; Fernandes ve ark., 2005). YZ desteğiyle geliştirilecek uygulamaların kullanımı ile hastaların triyajında doğru tanıya hızlıca götürerek oldukça faydalı olacağından bu alanda yeni sistemlere ihtiyaç olduğu açıktır.

2.3. Yapay Zekanın Tarihsel Gelişimi

Akıllı davranışı ve eleştirel düşünmeyi dizayn etmek için bilgisayarları kullanma kavramı ilk olarak 1950'de Alan Turing tarafından tanımlandı (Ramesh et al. 2004). Bilgisayarlar ve Zeka kitabında, bilgisayarların akıllı olup olmadığını belirlemek için daha sonra "Turing testi" olarak anılacak olan basit bir testi tanımladı. Altı yıl sonra John McCarthy, "yapay zeka (YZ) terimini "akıllı makineler üretme bilimi ve mühendisliği olarak tanımladı (Greenhill ve Edmunds, 2020). "Yapay zeka" kavramı ilk defa 1956 yılında New Hampshire'daki Dortmund kolejinde yapay zeka üzerine Dartmouth yaz araştırma projesine ev sahipliği yapan Marvin Minsky ve John McCarthy tarafından kullanılmıştır (McCarthy ve ark., 2006; Şekil 2.3). Devam eden yıllarda 1950'lerden 1960'lara kadar mühendislik ve robotik cihazlar alanında önemli gelişmeler yaşansa da bu dönemler tıbbın yapay zekayı benimsemede geride kaldığı dönemlerdi. 1960'ların sonunda Ulusal Tıp Kütüphanesi tarafından Tıbbi Literatür Analizi ve Erişim Sisteminin ve PubMed'in (web tabanlı arama motoru)

geliştirilmesi, biyotıp alanında gelişmelerin hızlanması için önemli bir dijital kaynak haline geldi (Kulikowski, 2019). Klinik bilişim veritabanları ve tıbbi kayıt sistemleri de ilk kez bu dönemde geliştirildi ve tıpta yapay zekanın gelişimi için temel oluşturmaya yardımcı oldu (Hamet ve Tremblay, 2017). 1970'lerden 1980'li yılların sonunda kadar olan büyük zaman diliminde “ yapay zekanın kış dönemi” olarak adlandırılan yapay zekaya olan finansmanın, ilginin ve gelişmelerin azaldığı duraksama dönemi yaşandı (Greenhill ve Edmunds 2020). 1980-1990'lı yıllarda makine öğrenimine olan ilgi yeniden canlandı ve yeni geliştirilen karar destek algoritmaları (DXplain sistemi) ile tıpta ayırıcı tanıya katkı sağlayan sistemler geliştirildi (Amisha ve ark., 2019). 2000'li yıllarda ise doğal dil işleme yöntemindeki gelişmeler ile sohbet robotları yüzeysel iletişimden (Eliza) anlamlı konuşmaya dayalı ara yüzlere dönüştürüldü. Bu teknoloji, 2011'de Apple'ın sanal asistanı olan Siri'ye ve 2014'te Amazon'un sanal asistanı olan Alexa'ya uygulandı. 2015'te Pharmabot olarak adlandırılan, pediatri hastalarının ve hastaların bakımından sorumlu olan kişilerin ilaç eğitimine destek amaçlı sohbet robotu geliştirildi. Bu gelişmeler ile yazılım programlarının ve diğer gelişmiş bilgisayar donanımlarının yanı sıra; dijitalleştirilmiş tıp daha kolay erişilebilir hale geldi ve tıp alanında yapay zeka ivme kazandı (Comendador ve ark., 2015). Günümüzde ise yapay zekanın rutin klinik uygulamanın parçası olmaya başladığı tıpta yeni bir çağdayız. Ancak yapay zeka algoritmaları ve uygulamalarının bu alanda daha fazla çalışmaya ve doğrulanmaya ihtiyacı olduğu açık. Oluşturulacak algoritmaların etkinliğini; tanı koymada, tedavi planlamada ve terapötik sonuçları tahmin etmedeki becerilerini arttırabilmek için ek klinik verilere ve çalışmalara ihtiyaç duyulacaktır. Hekimlerin ve hastanelerin hizmet kalitesini azaltmadan iş yükünü düşürmek için yapay zekayı günlük klinik kullanıma dahil etmelerine olanak sağlanmalı ve buna uygun maliyetli yapay zeka modelleri ve ürünleri geliştirilmelidir.




Şekil 2.3. Yapay Zekanın Kronolojik Tarihi (Arslan, 2020; McCarthy ve ark., 2006'dan değiştirilerek kullanılmıştır)

2.4. Yapay Zeka ve Sağlık Alanındaki Uygulamalar

YZ yöntem ve araçları, 20. yüzyılın ortalarından itibaren başlayıp zamanla sağlık alanında da uygulama yeri bulmaktadır. Özellikle son yirmi yılda sağlık sektöründe YZ ya olan ilgi ve ihtiyaç da artış görülmektedir (Ramesh ve ark., 2004). Sağlık hizmetlerinde en çok yararlanılanlar arasında teşhis- tedavi ve terapotik yanıtın tahmini için kullanılan robotik uygulamalar yer almaktadır. Buna ek olarak bulanık mantık ve yapay sinir ağları gibi modellemelerde diğer çok kullanılan YZ teknikleridir (Rigla ve ark., 2018). Yapay zeka tabanlı programlar ve uygulamalar sağlık alanında sürekli yapılan görevlerin hızlandırılması, tanı sürecinin kolaylaştırılması; kişiye özel, öngörücü ve koruyucu sağlık hizmetlerinin kolay ulaşılabilir hale getirilmesinde kullanılmaktadır (Schwendicke ve ark., 2020). Sağlığın tüm alanlarında yapay zeka çalışmaları umut vericidir. Tanı sürecini kolaylaştırmak ve hızlandırmak için çalışmalar devam etmektedir. Özellikle acil servis hizmetleri gibi hızın önemli olduğu kliniklerde yapay zeka destekli uygulamaların kullanımı hastaları hastalıklarına ve aciliyet durumlarına göre gruplandırıp hızlı ve kaliteli hizmet sunmada direkt etkilidir. Bu nedenle, YZ uygulamalarının acil servis hizmetlerinde iyileşme sağlamak için kullanılması önemli bir yeri bulunmaktadır (Berlyand ve ark., 2018).

Bu amaçlarla geliştirilen başlıca yapay zeka yöntemleri; bulanık mantık, uzman sistemler, yapay sinir ağları, genetik algoritmalarıdır. Uzman sistemler, belli konudaki

uzmanların muhakeme ve karar verme işlerini modelleyebilen bilgisayar sistemleridir. İyi geliştirilmiş bir uzman sistem yönteminin, alanında uzman olan kişilerin yapabildiği tasarlama, planlama, gruplandırma, teşhis etme, öngörme, yorumlama, genelleme, kontrol etme, tavsiyelerde bulunma ve sonuca karar verme gibi işlemleri benzer şekilde yapabilme özellikleri vardır (Nabiyev VV. Yapay Zeka. Ankara: Seçkin Yayınları, 2003.). Tıbbi uzman sistemler ise tıp alanındaki yapısal soruları çözüp yanıtlamak için geliştirilmiştir. Tıbbi uzman sistemler bir veya birden çok alanında uzman kişilerin tavsiyeleri ile geliştirilir. Bu sayede en uygun sorular sorularak doğru yanıtların elde edilmesi sağlanır. Tıbbi uzman sistemlerinin amacı sanılanın aksine uzman hekimin yerine geçmekten çok elde edilen verilere dayanarak, hekime yol gösterici önerilerde bulunmaktadır (Babalık, 2000). “Tıbbi yapay zeka”nın esas ilgilendiği klinik teşhisi koyabilecek, tedavi için öneride bulunabilecek programların oluşturulmasıdır. YZ, Şekil 2’de görüldüğü gibi birçok farklı araç, yöntem ve algoritma içermektedir (Çilhoroz ve Işık, 2021).



Şekil 2.4. Sağlık Hizmetlerinde Yapay Zeka Modellemeleri/ Algoritmaları (Çilhoroz ve Işık, 2021’den değiştirilerek kullanılmıştır).

3. GEREÇ VE YÖNTEMLER

3.1. Araştırmanın Yeri ve Zamanı

3.1.1. Araştırmanın yeri

Bu araştırma Sakarya ili Adapazarı ilçesinde bulunan Sakarya Üniversitesi Tıp Fakültesine bağlı olarak Sakarya Eğitim ve Araştırma Hastanesi Radyoloji Kliniğinde yapılmıştır.

3.1.2. Araştırmanın zamanı

Araştırma 01.06.2023 ile 23.07.2024 arasındaki 14 aylık dönemde yürütülmüştür. Etik kurul onayı 02.05.2023'te alınmıştır. Araştırmanın verileri 01.06.2023 ile 01.08.2023 arasındaki 2 aylık süreçte toplanmıştır.

3.2. Araştırmanın Tipi

Bu araştırmanın tipi tanımlayıcı metodolojik araştırmadır.

3.3. Araştırmanın Evreni ve Örneklemi

Araştırmanın örneklemi Sakarya Eğitim ve Araştırma Hastanesinde kırık tanısıyla çekilen 940 hastadan alınan 1032 direkt grafi ile 250 sağlam hastadan alınan 250 fraktür olmayan grafi oluşturmaktadır. Araştırmanın genellenebileceği herhangi bir evren bulunmamaktadır.

3.4. Veri Toplama Araçları ve Yöntemleri

3.4.1. Veri toplama araçları

Veriler Sakarya Eğitim ve Araştırma Hastanesinin hasta bilgi ve yönetim sisteminden jpeg formatında elde edilmiştir. Araştırmacılar tarafından acil servise başvurup eklem grafisi çekilen hastaların grafileri incelenmiş ve fraktürü olan hastalar tespit edilerek grafi görüntüleri kaydedilmiştir.

3.4.2. Araştırmanın insan gücü

Araştırmanın insan gücünü Sakarya Üniversitesi Tıp Fakültesi Radyoloji Kliniğinden bir öğretim üyesi ve bir araştırma görevlisi olmak üzere toplamda 2 hekim oluşturmaktadır.

3.5. Araştırmanın Süreci

Araştırmanın konusu 2021 yılı Aralık ayında belirlendi. Ocak 2022–Şubat 2023 tarihleri arasında araştırma için ayrıntılı literatür taraması yapıldı. Literatür taraması sonrası araştırma planlaması yapıldı ve gerekli izinler alındı. 01.06.2023 ile 01.08.2023 tarihleri arasında araştırma verileri toplandı. Daha sonrasında 01.08.2023–23.07.2024 tarihleri arasında araştırma verileri analiz edildi ve analiz sonuçlarına göre araştırma raporu hazırlandı.

3.6. Etik Kurul Onayı ve İzinler

Araştırma için Sakarya Üniversitesi Girişimsel Olmayan Etik Kurulunun 02/05/2023 tarih ve E-71522473-050.01.04-241683-129 sayılı izni ile çalışmaya başlanmıştır (Ek-1). Etik kurul değerlendirme raporlarının bir parçası olarak Sakarya Eğitim ve Araştırma Hastanesi başhekimliğinden de araştırmanın yapılabilmesi için yazılı izin alınmış ve yazılı izin Sakarya Üniversitesi Girişimsel Olmayan Etik Kuruluna teslim edilmiştir.

3.7. Araştırmanın Bütçesi

Araştırmada kullanılan kırtasiye malzemelerinin giderleri araştırmacılar tarafından karşılanmıştır. Kırtasiye malzemeleri dışında bir gider yoktur. Araştırma için herhangi bir destek alınmamıştır.

3.8. Araştırmanın Sınırlılıkları

Bu araştırma klinikte kullanılabilecek modellerin performansı hakkında fikir vermesi için tasarlandığından ve kısıtlı insan gücüne sahip olduğundan çok büyük veri setleri ile model oluşturulamamıştır. Daha kısıtlı veri setleri ile oluşturulan modelin klinikte faydalı olup olamayacağı test edilmiştir.

3.9. İstatistiksel Analiz

Çalışmaya dahil edilen hastalara ait direkt grafipler, fraktür olan ve fraktür olmayan olarak iki gruba ayrılmıştır. Yapay zeka algoritmasının fraktür olup olmadığını daha doğru ve daha yüksek oranda belirleyebilmesi için öncelikle ham grafi imajlarına gürültü ekleme, bulanıklaştırma, kırma, çevirme ve döndürme gibi görüntü işleme teknikleri uygulanmıştır. Bu sayede her bir imaj için 10 farklı görüntü üretilmiştir. Transfer learning metodu ile makine öğrenimi gerçekleştirilmiştir. Çalışmaya dahil edilen direkt grafi görüntülerinin %80'i eğitim verisi olarak kullanılırken %20'si test

verisi olarak kullanılmıştır ve modelin başarı parametreleri test veri seti ile hesaplanmıştır.

4. BULGULAR


Araştırmaya direkt grafilere dahil edilen fraktürü olan toplamda 940 hasta vardır. Bu hastaların %67,8'i (n=637) erkek, %32,2'si (n=303) kadındır. Katılımcıların yaş ortalaması $30,77 \pm 23,02$ yıl, yaş ortancası 27,00 [10,00-48,00] yıldır. En küçük katılımcı 1, en büyük katılımcı ise 95 yaşındadır. Katılımcıların %40,4'ü (n=380) 18 yaşından küçük, %50,9'u (n=478) 18 yaşında veya daha büyük ve 65 yaşından küçük, %8,7'si (n=82) 65 yaşında veya daha büyüktür (Tablo 4.1, Şekil 4.1, Şekil 4.2).

Tablo 4.1. Araştırmaya dahil edilen hastaların demografik özellikleri

Değişkenler		n (%)
Cinsiyet	Erkek	637 (67,8)
	Kadın	303 (32,2)
Yaş grubu	<18 yaş	380 (40,4)
	≥ 18 ve <65 yaş	478 (50,9)
	≥ 65 yaş	82 (8,7)



Şekil 4.1. Araştırmaya dahil edilen hastaların cinsiyet dağılımı




Şekil 4.2. Araştırmaya dahil edilen hastaların yaş dağılımı


Katılımcıların %25,0'ında (n=235) radius kemiğinde, %16,0'ında (n=150) falanks kemiklerinde, %8,6'sında (n=81) metatarsal kemiklerde, %8,3'ünde (n=78) radius ve ulna kemiklerinde birlikte, %6,8'inde (n=64) humerus kemiğinde, %6,4'ünde (n=60) femur kemiğinde, %6,0'ında (n=56) klavikula kemiğinde, %5,3'ünde (n=50) fibula ve tibia kemiklerinde birlikte, %5,0'ında (n=47) metakarpal kemiklerde, %4,1'inde (n=39) tibia kemiğinde, %3,5'inde (n=33) fibula kemiğinde, %2,9'unda (n=27) ulna kemiğinde, %0,9'unda (n=8) tarsal kemiklerde, %0,4'ünde (n=4) pelvis kemiklerinde, %0,3'ünde (n=3) karpal kemiklerde, %0,2'sinde (n=2) skapula kemiğinde, %0,2'sinde (n=2) patella kemiğinde, %0,1'inde (n=1) femur ve fibula kemiklerinde birlikte kırık mevcuttur. Araştırmaya katılan hastaların %34,7'sinde (n=326) nondeplase kırık, %34,0'ında (n=320) deplase kırık, %27,4'ünde (n=258) parçalı kırık, %3,1'inde (n=29) torus kırığı, %0,7'sinde (n=7) kopma kırığı mevcuttur (Tablo 4.2, Şekil 4.3, Şekil 4.4).

Tablo 4.2. Araştırmaya dahil edilen hastaların kırık lokalizasyonları ve kırık tipleri

Değişkenler		n (%)
Kırık lokalizasyonu	Radius	235 (25,0)
	Falankslar	150 (16,0)
	Metatarsal kemikler	81 (8,6)
	Radius ve ulna	78 (8,3)
	Humerus	64 (6,8)
	Femur	60 (6,4)
	Klavikula	56 (6,0)
	Fibula ve tibia	50 (5,3)
	Metakarpal kemikler	47 (5,0)
	Tibia	39 (4,1)
	Fibula	33 (3,5)
	Ulna	27 (2,9)
	Tarsal kemikler	8 (0,9)
	Pelvis kemikleri	4 (0,4)
	Karpal kemikler	3 (0,3)
	Skapula	2 (0,2)
	Patella	2 (0,2)
	Femur ve fibula	1 (0,1)
Kırık tipi	Nondeplase	326 (34,7)
	Deplase	320 (34,0)
	Parçalı	258 (27,4)
	Torus	29 (3,1)
	Kopma	7 (0,7)



Şekil 4.3. Araştırmaya dahil edilen hastaların kırık lokalizasyonlarının dağılımı



Şekil 4.4. Araştırmaya dahil edilen hastaların kırık tiplerinin dağılımı

4.1. Yapay zeka modelinin oluşturulması

Çalışmaya dahil edilen hastalara ait direkt grafiler, fraktür olan ve olmayan olarak iki gruba ayrılmıştır. Yapay zeka algoritmasının fraktür olup olmadığını daha doğru ve yüksek oranda belirleyebilmesi için öncelikle ham grafi imajlarına gürültü ekleme,

bulanıklaştırma, kırma, çevirme ve döndürme gibi görüntü işleme teknikleri uygulanmıştır. Bu sayede her bir imaj için 10 farklı görüntü üretilmiştir. Transfer learning metodu ile makine öğrenimi gerçekleştirilmiştir. Çalışmaya dahil edilen direkt grafi görüntülerinin %80'i eğitim datası olarak kullanılırken %20'si test datası olarak kullanılmıştır ve modelin başarı parametreleri test veri seti ile hesaplanmıştır. Test seti biası önlemek ve randomizasyonu sağlamak amacıyla rastgele kodlanarak seçilmiştir. Yapay zekanın test veri setindeki başarısı sensitivite (duyarlılık), spesifite (özgüllük), precision (kesinlik), negatif prediktif değer, yanlış pozitiflik oranı, yanlış negatiflik oranı, accuracy (doğruluk) ve F1 skoru hesaplanarak ifade edilmiştir.

Toplamda 940 fraktörü olan hastanın 848'inden birer, 92'sinden ikişer direkt grafi araştırmaya dahil edilmiştir. Böylece 1032 adet fraktür olan direkt grafiden 832'si eğitim setinde 200'ü test setinde kullanılmıştır. Modelin eğitim setini 1032 direkt grafi (832 fraktörü olan, 200 sağlam) oluştururken test setini ise 258 direkt grafi oluşturmuştur. Eğitim seti öncelikle görüntü işleme teknikleri ile artırılmıştır. Direkt graflerin çekim yönleri, dozları gibi özellikleri değişiklik gösterebileceğinden dolayı bir imajdan birden fazla muhtemel varyasyon ve kalitede imaj elde ederek daha az sayıdaki eğitim datasından, daha yüksek sayıda eğitim datasına ve böylece daha yüksek doğru tahmin seviyelerinin elde edilmesi hedeflenmiştir. Bunun için her grafiye gürültü ekleme, bulanıklaştırma, kırma, çevirme ve döndürme gibi görüntü işleme teknikleri uygulanmıştır ve bir imajdan 10 farklı imaj elde edilmiştir. Bu sayede 1032 orjinal grafiden 10 320 grafi elde edilmiştir.

Bir grafiden elde edilen farklı imajlar birer örnek ile görselleştirilmiştir (Resim 4.1-4.5).




Resim 4.1. Herhangi bir görüntü ilemi yöntemi uygulanmamış direkt grafi örneği



Resim 4.2. “Gürültü ekleme” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği




Resim 4.3. “Bulanıklaştırma” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği



Resim 4.4. “Kırpma” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği



Resim 4.5. “Çevirme” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği



Resim 4.6. “Döndürme” görüntü işleme yöntemi ile üretilmiş direkt grafi örneği

Eğitim setindeki tüm imajlar transfer learning metodu ile eğitilmiştir. Test setindeki 250 grafi, oluşturulan model ile tahmin edilmiştir. Model kırığı olan hastaların %82’sini kırık olarak tahmin etmektedir (Sensitivite-Duyarlılık). Sağlam olan hastaların %88’ini sağlam olarak tahmin etmektedir (Spesifisite-Özgüllük). Modelin kırık olarak tahmin ettiği hastaların %97’si gerçekte kırıktır (Precision-Kesinlik). Modelin sağlam olarak tahmin ettiği hastaların %54’ü gerçekte sağlamdır (Negatif prediktif değer). Model sağlam hastaların %12’sini kırık olarak tahmin etmektedir (Yanlış pozitiflik oranı). Model kırık hastalarının %18’ini sağlam olarak tahmin etmektedir (Yanlış negatiflik oranı). Modelin tüm hastalar içinde doğru (kırık hastaya kırık, sağlam hastaya sağlam) tahmin yapma sıklığı ise %83’tür (Accuracy-Doğruluk). Modelin F1 skoru 0,89’dur (Tablo 4.3).

Tablo 4.3. Fraktür olan ve olmayan iki gruba ait test veri setinin yapay zeka ile değerlendirilmesine ait sonuçlar

Ölçüm	Değer
-------	-------

Duyarlılık	0,82
Özgüllük	0,88
Kesinlik	0,97
Negatif prediktif değer	0,54
Yanlış pozitiflik oranı	0,12
Yanlış negatiflik oranı	0,18
Doğruluk	0,83
F1 skoru	0,89

5. TARTIŞMA VE SONUÇ

Mevcut araştırmada 940 fraktürü olan hastadan elde edilen 1032 fraktür direkt grafisi ve 258 fraktürü olmayan hastadan elde edilen 258 sağlam hasta direkt grafisi kullanılmıştır. Bu direkt grafilerden 1040'ı eğitim verisi olarak modeli oluşturmak için kullanılırken, 250'si test verisi olarak modeli test etmek için kullanılmıştır. Test sonucu modelin duyarlılığı 0,82, özgüllüğü 0,88, kesinliği 0,97, negatif prediktif değeri 0,54, yanlış pozitiflik oranı 0,12, yanlış negatiflik oranı 0,18, doğruluğu 0,83 ve F1 skoru 0,89 olarak tespit edilmiştir.

Mevcut araştırmada fraktürü olan ve grafisi araştırmaya dahil edilen hastaların %67,8'i (n=637) erkek, %32,2'si (n=303) kadındı. Katılımcıların %40,4'ü (n=380) 18 yaşından küçük, %50,9'u (n=478) 18 yaşında veya daha büyük ve 65 yaşından küçük, %8,7'si (n=82) 65 yaşında veya daha büyüktü. Katılımcıların yaş ortalaması 30,77±23,02 yıl, yaş ortancası 27,00 [10,00-48,00] yılı. Katılımcıların en sık olarak %25,0'ında (n=235) radius kemiğinde, %16,0'ında (n=150) falanks kemiklerinde, %8,6'sında (n=81) metatarsal kemiklerde fraktürü mevcuttu.

Zararsız ve arkadaşlarının Ekim 2007 ile Ekim 2008 tarihleri arasında Mustafa Kemal Üniversitesi Tayfur Ata Sökmen Tıp Fakültesi Hastanesi acil servisine başvuran kırık hastalarını dahil ettikleri araştırmalarında mevcut araştırmaya benzer şekilde kırığı bulunan 62 hastanın %61,3'ü erkek %38,7'si kadın; %63,0'ı erişkin %37,0'ı çocuktü. En sık kırık bulunan kemikler ise femur, radius ve tibia idi (Zararsız ve ark., 2009).

Haziran 2016 ile Kasım 2018 tarihleri arasında Kars Hırakani Devlet Hastanesinde kırık tanısı almış 599 hastanın dahil edildiği araştırmada hastaların %81,6'sı erkek, %18,3'ü kadındı. Katılımcıların yaş ortalaması 35,6±29,4 yılı. Kırık lokalizasyonları en sık Radius-ulna, humerus ve fibula idi (Pamuk, 2019). Katılımcıların cinsiyet ve yaş dağılımı, kırık lokalizasyonlarının dağılımı mevcut araştırma ile benzerdi.

Araştırmaya dahil edilen hastaların grafi ve kırık lokalizasyonlarının dağılımının gerçek hayatta kliniğe başvuran hastaların dağılımları ile benzer olmasını,

oluşturulan modelin klinik kullanımında sağlayacağı faydayı maksimize etmek açısından değerli görmekteyiz.

Sadece femur boyun kırıklarının tespit edilmesi için derin öğrenme ve genetik algoritma yaklaşımlarının değerlendirildiği başka bir araştırmada toplamda 234 anteroposterior pelvis grafisi dahil edilmiş ve model oluşturulmuştur. Oluşturulan modelin duyarlılığı 0,83 özgüllüğü ise 0,73 olarak tespit edilmiştir (Beyaz ve ark., 2020). Mevcut araştırmaya göre düşük duyarlılık ve özgüllük düzeyleri, modeli oluşturmak için kullanılan eğitim setinin mütevazı sayısından kaynaklanıyor olabilir. Proksimal femur kırıklarını yapay zeka ile tespit edebilmek için yapılan bir başka araştırmada 610 direkt grafi araştırmaya dahil edilmiş ve 0,97 duyarlılık, 0,97 özgüllük tespit edilmiştir. Araştırmanın yöntemi incelendiğinde eğitim ve test setine dahil edilen direkt grafilere; görüntünün merkezinde proksimal femurun bulunduğu dikdörtgen şekilli özel bir ilgi alanının manuel olarak kırıldığı tespit edilmiştir. Bu özel ilgi alanı, üst asetabulumdan küçük trokanterin yaklaşık 5 cm altındaki proksimal femoral diafizine kadar uzanmaktadır (Yu ve ark., 2020). Bu ilgi alanı seçimi, modelin kemik şeklini kolay öğrenmesini ve kırığı kolay tespit etmesini sağlamış böylece yüksek duyarlılık ve özgüllüğe ulaşmayı sağlamış olabilir. Ancak dezavantaj olarak proksimal femur dışında direk grafi alanına giren pelvis kemikleri ve sakrumda oluşabilecek fraktür hatlarında sonucu tahmin etmede yardımcı olamayacaktır. Proksimal femur kırıklarının tespit edilmesi için derin öğrenme tekniklerinin kullanıldığı başka bir araştırmada 1063 direkt grafi eğitim seti olarak kullanılmıştır. Daha sonrası 2 ayrı gelişmiş veri artırma tekniği kullanılarak eğitim seti genişletilmiştir. Bu gelişmiş veri artırma teknikleri; üretken rakip ağlar tekniği ile dijital olarak yeniden yapılandırılmış radyografiler teknikleridir. Ve nihayetinde oluşturulan modelin test setinde duyarlılığı 0,91, özgüllüğü ise 0,93 bulunmuştur. Bu araştırmada gelişmiş veri artırma tekniklerinin modelin duyarlılığını ve özgüllüğünü yükselttiği gösterilmiştir (Mutasa ve ark., 2020). Mevcut araştırmada ise gelişmiş veri artırma teknikleri kullanılmamıştır. Literatürde aynı bölge üzerinde yapılmış yapay zeka ile kırık tespiti araştırmalarında bile, farklı sayıda grafinin dahil edilmesi ve farklı yöntemlerin kullanılması ile birbirinden farklı sonuçların elde edildiği görülmektedir.

Ahmed ve Hawezi'nin Doğu Erbil Acil Hastanesi'nde makine öğrenmesi yoluyla kemik kırıklarını saptamak amacıyla yaptıkları araştırmada, doğruluk 0,64 ile 0,92 arasında, kesinlik ise 0,84 ile 0,94 arasında bulunmuştur. Mevcut araştırmada doğruluk 0,83 kesinlik ise 0,97 saptanmıştır ve araştırma sonuçları benzerdir. Bu araştırmada 270 direkt grafi kullanılmış ancak her bir grafiden farklı özellikler, farklı uzaklıklar ve farklı açılarda döndürmeler ile 140 farklı direkt grafi elde edilmiştir. Mevcut araştırmada daha fazla direkt grafi kullanıldığı halde 0,92 doğruluk oranına ulaşamamış ancak mevcut araştırmanın da kesinliği daha yüksek saptanmıştır. Bu farklılığın mevcut araştırmada dahil edilen direkt grafilerde fraktür sıklığının yüksek, sağlam olma sıklığının düşük olmasından kaynaklandığı düşünülmektedir. Bu nedenle mevcut araştırmada model; fraktür tahminini daha yüksek bir sıklıkla doğru bilirken, sağlam tahmininde daha düşük doğru bilme sıklığına ulaşmaktadır. Ahmed ve Hawezi'nin araştırmalarına dahil ettikleri grafilerin %22,2'si (n=60) kırık, %77,8'i (n=210) sağlam grafidir. Dahil ettikleri grafilerin ne kadarının eğitim datası ne kadarının test datası olarak kullanıldığı bilgisi araştırmada paylaşılmamaktadır. Ayrıca bu araştırmada sadece bacak kemiklerinin kullanılması eğitim datası az olmasına rağmen daha yüksek doğruluğa ulaşmasını sağlamış olabilir (Ahmed ve Hawezi, 2023).

Vertebral kırıkların tespit edilmesi için derin öğrenme algoritmalarının kullanıldığı bir araştırmada model eğitimi için 1306 görüntü kullanılmış ve oluşturulan modelin duyarlılığı 0,73, özgüllüğü 0,73 tespit edilmiştir (Chen ve ark., 2021). Yine vertebral kırıkların tespiti için yapay zekanın kullanıldığı ve 300 radyografi ile modelin eğitildiği başka bir araştırmada duyarlılık 0,84, özgüllük 0,87 olarak tespit edilmiştir (Murata ve ark., 2020). Bu araştırmada daha düşük veri setiyle daha yüksek duyarlılık ve özgüllük seviyelerine ulaşılmış olması, yöntemde ciddi farklılıklar olması ile açıklanabilir. Nitekim bu araştırmada hem görüntülerin seçiminde daha seçici davranılması hem de görüntüleme yöntemlerinde MR'dan destek alınması daha az veri setiyle daha yüksek duyarlılık ve özgüllük düzeyinin elde edilmesini sağlamış olabilir.

Kırık tespitinde derin öğrenme ve yapay zekanın etkisini değerlendirmeyi hedefleyen ve 32 araştırmadan 55 061 görüntünün veri havuzuna dahil edilmesi ile yapılan bir metaanalizde; modelin duyarlılığı 0,91 ve özgüllüğü 0,91 tespit edilmiştir. Aynı

araştırmada klinisyenlerin kırık tespitinde duyarlılığı 0,94 ve özgüllüğü 0,94 tespit edilmiş ve model ile klinisyenlerin performansı arasında anlamlı fark tespit edilememiştir. Ancak yapay zeka yardımının eklenmesi ile klinisyen performansının arttığı duyarlılığın 0,97, özgüllüğün 0,92 olduğu ve metaanalize dahil edilen bir çalışmada yapay zeka yardımının klinisyenlerin tanıya ulaşma süresini kısalttığı ortaya konulmuştur. Ancak yazarların belirttiği önemli bir nokta ise metaanalize dahil edilen araştırmalarda klinisyenlere klinik bilginin verilmemiş olmasıdır. Klinisyenlere klinik bilginin verilmesi ile klinisyen performansları daha yüksek seviyelere çıkabilir (Kuo ve ark., 2022). Mevcut araştırmada model performansının yanında klinisyen performansı değerlendirilmemiştir. Metaanalizde duyarlılık ve özgüllüğün mevcut araştırmaya göre yüksek olması, veri setinin çok daha büyük olması ve dahil edilen araştırmalarda tek bir bölge üzerinde yapılan çalışmaların sık olması ile ilgili olabilir.

Araştırmanın kısıtlılıkları:

Mevcut araştırma klinikte kullanılmak üzere geliştirilebilecek çok daha kapsamlı modellerin bir ön çalışması olduğu için görece kısıtlı bir veri seti kullanılmıştır.

Bu araştırmada modelin eğitimi için dahil edilen grafipler arasında, fraktür bulunan grafi sayılarına göre fraktür bulunmayan grafi sayıları daha az olduğu için oluşturulan modelin sağlam olarak tahmin ettiği grafiplerin doğru tahmin edilme oranı daha düşüktür.

Mevcut araştırmada derin öğrenme yöntemi ile oluşturulan modelin başarısının yanında klinisyenlerin başarıları değerlendirilmemiş, mevcut test datasının klinikte ne doğrulukta değerlendirileceği konusu belirsiz kalmıştır. Ancak araştırmanın amacı oluşturulan modelin klinisyenlere bir alternatif olması değil, klinisyenlerin doğru karar vermesine yardımcı olacak bir karar destek sistemi oluşturulmasıdır.

Araştırmada oluşturulan model, kırık olan bölgenin lokasyonunu tespit edememekte, ancak grafide kırık vardır ya da yoktur gibi bir sonuç verebilmektedir.

Araştırmanın güçlü yanları:

Araştırmada belli bir tarih aralığında acil servise başvurusu olan fraktür tanılı hastalar kullanıldığı ve arasından özel bir seçim yapılmadığı için ve test datası da bu

verisetinden rastgele seçildiği için, hem model eğitimi hem de duyarlılık ve özgüllük sonuçları gerçek hayat deneyimlerine uygun olarak yapılmıştır.

Birçok araştırmanın aksine mevcut araştırmada yalnızca belli bir anatomik bölge fraktürleri değil, tüm vücutta meydana gelebilecek fraktürler değerlendirilmiştir.

Sonuç olarak:

Yapay zeka ile kemik kırıklarının tespit edilmesi için oluşturulan modeller yüksek doğruluklarla sonuç vermektedir.

Daha büyük veri setlerinin eğitim datası olarak kullanılmasıyla daha yüksek doğruluk yüzdelerine ulaşılabilir.

Yine de yapay zeka modellerinin performansı klinisyenlerin performansı kadar yüksek değildir ancak yapay zeka modelleri birlikte kullanıldığında klinisyen performansları artabilmekte klinisyenlerin karara ulaşma süreleri kısalabilmektedir. Bu nedenle bir karar destek sistemi olarak klinikte kullanılabilir. Bu sayede hem kırık teşhisinin atlanma ihtimali azaltılabilir hem de acil servis gibi hızlı karar vermenin önem arz ettiği kliniklerde zamandan tasarruf edilebilir.

6. KAYNAKLAR

- Abbott, A., Bird, M. L., Wild, E., Brown, S. M., Stewart, G., & Mulcahey, M. K. (2020). Part I: epidemiology and risk factors for stress fractures in female athletes. *The Physician and Sportsmedicine*, 48(1), 17–24.
- Ahmed, K. D., & Hawezi, R. (2023). Detection of bone fracture based on machine learning techniques. *Measurement: Sensors*, 27, 100723.
- Amin, S., Achenbach, S. J., Atkinson, E. J., Khosla, S., & Melton, L. J., 3rd. (2014). Trends in fracture incidence: a population-based study over 20 years. *Journal of Bone and Mineral Research: The Official Journal of the American Society for Bone and Mineral Research*, 29(3), 581–589.
- Amisha, Malik, P., Pathania, M., & Rathaur, V. K. (2019). Overview of artificial intelligence in medicine. *Journal of Family Medicine and Primary Care*, 8(7), 2328–2331.
- Atlan, F., & Pençe, İ. (2021). Yapay zekâ ve tıbbi görüntüleme teknolojilerine Genel bakış. *Acta Infologica*, 5(1), 207–230.
- Babalık A. (2000) Uzman Sistemlerin Tıpta Teşhis Amaçlı Kullanımı, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara (Danışman: Prof. Dr. İnan Güler).
- Bergh, C., Wennergren, D., Möller, M., & Brisby, H. (2020). Fracture incidence in adults in relation to age and gender: A study of 27,169 fractures in the Swedish Fracture Register in a well-defined catchment area. *PloS One*, 15(12), e0244291.
- Berlyand, Y., Raja, A. S., Dorner, S. C., Prabhakar, A. M., Sonis, J. D., Gottumukkala, R. V., Succi, M. D., & Yun, B. J. (2018). How artificial intelligence could transform emergency department operations. *The American Journal of Emergency Medicine*, 36(8), 1515–1517.
- Beyaz, S., Açıcı, K., & Sümer, E. (2020). Femoral neck fracture detection in X-ray images using deep learning and genetic algorithm approaches. *Joint diseases and related surgery*, 31(2), 175.
- Bianchi, S. (2020). Ultrasound and bone: a pictorial review. *Journal of Ultrasound*, 23(3), 227–257.
- Chen, H. Y., Hsu, B. W. Y., Yin, Y. K., Lin, F. H., Yang, T. H., Yang, R. S., ... & Tseng, V. S. (2021). Application of deep learning algorithm to detect and visualize vertebral fractures on plain frontal radiographs. *PLoS One*, 16(1), e0245992.
- Choi, C., Lee, S. J., Choo, H. J., Lee, I. S., & Kim, S. K. (2021). Avulsion injuries: an update on radiologic findings. *Yeungnam University Journal of Medicine*, 38(4), 289–307.

Christ, M., Bingisser, R., & Nickel, C. H. (2016). Emergency Triage. An Overview. *Deutsche medizinische Wochenschrift*, 141(5), 329–335.

Christ, M., Grossmann, F., Winter, D., Bingisser, R., & Platz, E. (2010). Modern triage in the emergency department. *Deutsches Arzteblatt International*, 107(50), 892–898.

Cocco, G., Ricci, V., Villani, M., Delli Pizzi, A., Izzi, J., Mastandrea, M., Boccata, A., Naňka, O., Corvino, A., Caulo, M., & Vecchiet, J. (2022). Ultrasound imaging of bone fractures. *Insights into Imaging*, 13(1), 189.

Comendador, B. E. V., Francisco, B. M. B., Medenilla, J. S., Nacion, S. M. T., & Serac, T. B. E. (2015). Pharmabot: A pediatric generic medicine consultant chatbot. *Journal of Automation and Control Engineering*, 3(2), 137–140.

Cowan, R. M., & Trzeciak, S. (2005). Clinical review: Emergency department overcrowding and the potential impact on the critically ill. *Critical Care / the Society of Critical Care Medicine*, 9(3), 291–295.

Crockett, J. C., Rogers, M. J., Coxon, F. P., Hocking, L. J., & Helfrich, M. H. (2011). Bone remodelling at a glance. *Journal of Cell Science*, 124(Pt 7), 991–998.

Curtis, E. M., van der Velde, R., Moon, R. J., van den Bergh, J. P. W., Geusens, P., de Vries, F., van Staa, T. P., Cooper, C., & Harvey, N. C. (2016). Epidemiology of fractures in the United Kingdom 1988-2012: Variation with age, sex, geography, ethnicity and socioeconomic status. *Bone*, 87, 19–26.

Çilhoroz, Y. & Işık, O. (2021). Yapay Zekâ: Sağlık Hizmetlerinden Uygulamalar. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 23 (2) , 573-588.

Daffner, R. H., & Pavlov, H. (1992). Stress fractures: current concepts. *AJR. American Journal of Roentgenology*, 159(2), 245–252.

Durani, Y., Brecher, D., Walmsley, D., Attia, M. W., & Loiselle, J. M. (2009). The Emergency Severity Index Version 4: reliability in pediatric patients. *Pediatric Emergency Care*, 25(11), 751–753.

Farr, J. N., Melton, L. J., 3rd, Achenbach, S. J., Atkinson, E. J., Khosla, S., & Amin, S. (2017). Fracture Incidence and Characteristics in Young Adults Aged 18 to 49 Years: A Population-Based Study. *Journal of Bone and Mineral Research: The Official Journal of the American Society for Bone and Mineral Research*, 32(12), 2347–2354.

Fatovich, D. M., & Hirsch, R. L. (2003). Entry overload, emergency department overcrowding, and ambulance bypass. *Emergency Medicine Journal: EMJ*, 20(5), 406–409.

Fernandes, C. M. B., Tanabe, P., Gilboy, N., Johnson, L. A., McNair, R. S., Rosenau, A. M., Sawchuk, P., Thompson, D. A., Travers, D. A., Bonalumi, N., & Suter, R. E.

(2005). Five-level triage: a report from the ACEP/ENA Five-level Triage Task Force. *Journal of Emergency Nursing: JEN: Official Publication of the Emergency Department Nurses Association*, 31(1), 39–50; quiz 118.

Furkan, A. L. P., İşbay, B., & Özlem, Ö. N. E. R. (2023). Sağlık Alanında Yapay Zekâ Yöntemlerinin Kullanımına İlişkin Lisansüstü Tezlerin Bibliyometrik Analizi (2015-2022). *Gevher Nesibe Journal of Medical And Health Sciences*, 8(1), 228-237.

Gennari, C. (2001). Calcium and vitamin D nutrition and bone disease of the elderly. *Public Health Nutrition*, 4(2B), 547–559.

Greenhill, A. T., & Edmunds, B. R. (2020). A primer of artificial intelligence in medicine. *Techniques and Innovations in Gastrointestinal Endoscopy*, 22(2), 85–89.

Hamet, P., & Tremblay, J. (2017). Artificial intelligence in medicine. *Metabolism: Clinical and Experimental*, 69S, S36–S40.

Hashimoto, D. A., Rosman, G., Rus, D., & Meireles, O. R. (2018). Artificial Intelligence in Surgery: Promises and Perils. *Annals of Surgery*, 268(1), 70.

Hoffman, D. F., Adams, E., & Bianchi, S. (2015). Ultrasonography of fractures in sports medicine. *British Journal of Sports Medicine*, 49(3), 152–160.

Hosseini Nejad, H., Banaie, M., Seyedhosseini Davarani, S. H., & Khazaeipour, Z. (2016). Evaluation of the Significance of Vital Signs in the Up-Triage of Patients Visiting Emergency Department from Emergency Severity Index Level 3 to 2. *Acta Medica Iranica*, 54(6), 366–369.

Houthoofd, R., Ruyssinck, J., van der Hertten, J., Stijven, S., Couckuyt, I., Gadeyne, B., Ongenaes, F., Colpaert, K., Decruyenaere, J., Dhaene, T., & De Turck, F. (2015). Predictive modelling of survival and length of stay in critically ill patients using sequential organ failure scores. *Artificial Intelligence in Medicine*, 63(3), 191–207.

Hsu, H., Lacey, D. L., Dunstan, C. R., Solovyev, I., Colombero, A., Timms, E., Tan, H. L., Elliott, G., Kelley, M. J., Sarosi, I., Wang, L., Xia, X. Z., Elliott, R., Chiu, L., Black, T., Scully, S., Capparelli, C., Morony, S., Shimamoto, G., ... Boyle, W. J. (1999). Tumor necrosis factor receptor family member RANK mediates osteoclast differentiation and activation induced by osteoprotegerin ligand. *Proceedings of the National Academy of Sciences of the United States of America*, 96(7), 3540–3545.

Joshi, P., Lele, V., Gandhi, R., & Parab, A. (2012). Honda Sign On 18-FDG PET/CT in a Case of Lymphoma Leading to Incidental Detection of Sacral Insufficiency Fracture. *Journal of Clinical Imaging Science*, 2, 29.

Kaul, V., Enslin, S., & Gross, S. A. (2020). History of artificial intelligence in medicine. *Gastrointestinal Endoscopy*, 92(4), 807–812.

Kozaci, N., Ay, M. O., Avci, M., Beydilli, I., Turhan, S., Donertas, E., & Ararat, E. (2017). The comparison of radiography and point-of-care ultrasonography in the diagnosis and management of metatarsal fractures. *Injury*, 48(2), 542–547.

- Kulikowski, C. A. (2019). Beginnings of Artificial Intelligence in Medicine (AIM): Computational Artifice Assisting Scientific Inquiry and Clinical Art - with Reflections on Present AIM Challenges. *Yearbook of Medical Informatics*, 28(1), 249–256.
- Kuo, R.-J., Huang, M.-H., Cheng, W.-C., Lin, C.-C., & Wu, Y.-H. (2015). Application of a two-stage fuzzy neural network to a prostate cancer prognosis system. *Artificial Intelligence in Medicine*, 63(2), 119–133.
- Kuo, R. Y. L., Harrison, C., Curran, T.-A., Jones, B., Freethy, A., Cussons, D., Stewart, M., Collins, G. S., & Furniss, D. (2022). Artificial Intelligence in Fracture Detection: A Systematic Review and Meta-Analysis. *Radiology*, 304(1), 50–62.
- Matcuk, G. R., Jr, Mahanty, S. R., Skalski, M. R., Patel, D. B., White, E. A., & Gottsegen, C. J. (2016). Stress fractures: pathophysiology, clinical presentation, imaging features, and treatment options. *Emergency Radiology*, 23(4), 365–375.
- Mathews, K. S., Durst, M. S., Vargas-Torres, C., Olson, A. D., Mazumdar, M., & Richardson, L. D. (2018). Effect of Emergency Department and ICU Occupancy on Admission Decisions and Outcomes for Critically Ill Patients. *Critical Care Medicine*, 46(5), 720–727.
- May, T., & Marappa-Ganeshan, R. (2023). Stress Fractures. In StatPearls. StatPearls Publishing.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine*, 27(4), 12–12.
- McCormick, F., Nwachukwu, B. U., & Provencher, M. T. (2012). Stress fractures in runners. *Clinics in Sports Medicine*, 31(2), 291–306.
- McCoy, J. S., & Nelson, R. (2023). Avulsion Fractures. In StatPearls. StatPearls Publishing.
- Mohktar, M. S., Redmond, S. J., Antoniadis, N. C., Rochford, P. D., Pretto, J. J., Basilakis, J., Lovell, N. H., & McDonald, C. F. (2015). Predicting the risk of exacerbation in patients with chronic obstructive pulmonary disease using home telehealth measurement data. *Artificial Intelligence in Medicine*, 63(1), 51–59.
- Mohr, N. M., Wessman, B. T., Bassin, B., Elie-Turenne, M.-C., Ellender, T., Emlet, L. L., Ginsberg, Z., Gunnerson, K., Jones, K. M., Kram, B., Marcolini, E., & Rudy, S. (2020). Boarding of Critically Ill Patients in the Emergency Department. *Critical Care Medicine*, 48(8), 1180–1187.
- Moreira, C. A., & Bilezikian, J. P. (2017). Stress Fractures: Concepts and Therapeutics. *The Journal of Clinical Endocrinology and Metabolism*, 102(2), 525–534.

- Mueller, D., Schaeffeler, C., Baum, T., Walter, F., Rechl, H., Rummeny, E. J., & Woertler, K. (2014). Magnetic resonance perfusion and diffusion imaging characteristics of transient bone marrow edema, avascular necrosis and subchondral insufficiency fractures of the proximal femur. *European Journal of Radiology*, 83(10), 1862–1869.
- Murata, K., Endo, K., Aihara, T., Suzuki, H., Sawaji, Y., Matsuoka, Y., ... & Yamamoto, K. (2020). Artificial intelligence for the detection of vertebral fractures on plain spinal radiography. *Scientific Reports*, 10(1), 20031.
- Mutasa, S., Varada, S., Goel, A., Wong, T. T., & Rasiej, M. J. (2020). Advanced deep learning techniques applied to automated femoral neck fracture detection and classification. *Journal of Digital Imaging*, 33(5), 1209-1217.
- Nişancı, O. S. (2019). Acil servise başvuran 18-64 yaş arası bireylerde humerus, radius ve ulna kırıklarının anatomik ve epidemiyolojik olarak incelenmesi, Tokat Gaziosmanpaşa Üniversitesi Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, Tokat (Danışman: Prof. Dr. Birsen Özyurt)
- Pamuk, Ç. (2019). Bir devlet hastanesi acil servisinde kırık tanısı alan hastaların değerlendirilmesi. *Turkish Journal of Clinics and Laboratory*, 10(2), 163–167.
- Ramesh, A. N., Kambhampati, C., Monson, J. R. T., & Drew, P. J. (2004). Artificial intelligence in medicine. *Annals of the Royal College of Surgeons of England*, 86(5), 334–338.
- Ren, M., & Yi, P. H. (2022). Deep learning detection of subtle fractures using staged algorithms to mimic radiologist search pattern. *Skeletal Radiology*, 51(2), 345–353.
- Rigla, M., García-Sáez, G., Pons, B., & Hernando, M. E. (2018). Artificial Intelligence Methodologies and Their Application to Diabetes. *Journal of Diabetes Science and Technology*, 12(2), 303–310.
- Robling, A. G., Castillo, A. B., & Turner, C. H. (2006). Biomechanical and molecular regulation of bone remodeling. *Annual Review of Biomedical Engineering*, 8, 455–498.
- Schiller, J., DeFroda, S., & Blood, T. (2017). Lower Extremity Avulsion Fractures in the Pediatric and Adolescent Athlete. *The Journal of the American Academy of Orthopaedic Surgeons*, 25(4), 251–259.
- Sofka, C. M. (2006). Imaging of stress fractures. *Clinics in Sports Medicine*, 25(1), 53–62, viii.
- Squires, B., Allen, P. E., Livingstone, J., & Atkins, R. M. (2001). Fractures of the tuberosity of the calcaneus. *The Journal of Bone and Joint Surgery. British Volume*, 83(1), 55–61.
- Suda, T., Takahashi, N., Udagawa, N., Jimi, E., Gillespie, M. T., & Martin, T. J. (1999). Modulation of osteoclast differentiation and function by the new members of

the tumor necrosis factor receptor and ligand families. *Endocrine Reviews*, 20(3), 345–357.

Talan, T., & Kalinkara, Y. (2023). Yükseköğretimde Yapay Zekânın Rolü: Anatomi Dersi için ChatGPT Değerlendirmesi. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 7(1), 33–40.

Tanrıkulu, S., & Gönen, E. (2017). Kırık iyileşmesi. *TOTBİD Dergisi*, 16, 455-475.

Tarğal, A., Haberal, B., Şeşen, H., Demirkale, İ., Ateş, A., & Altay, M. (2018). Pediatrik Yaş Grubunda Acil Serviste 1 Yılda Tespit Edilen Ekstremitte Kırıklarının Etiyoloji ve Epidemiyolojisi: 1878 Çocuk İle Çalışma. *Akademik Araştırma Tıp Dergisi*, 2(2), 44–48.

Trzeciak, S., & Rivers, E. P. (2003). Emergency department overcrowding in the United States: an emerging threat to patient safety and public health. *Emergency Medicine Journal: EMJ*, 20(5), 402–405.

van der Velden, B. H. M., Kuijf, H. J., Gilhuijs, K. G. A., & Viergever, M. A. (2022). Explainable artificial intelligence (XAI) in deep learning-based medical image analysis. *Medical image analysis*, 79, 102470.

Weintraub, M. D., Hansford, B. G., Stilwill, S. E., Allen, H., Leake, R. L., Hanrahan, C. J., Chan, B. Y., Soltanolkotabi, M., Kobes, P., & Mills, M. K. (2020). Avulsion Injuries of the Hand and Wrist. *Radiographics: A Review Publication of the Radiological Society of North America, Inc*, 40(1), 163–180.

Whang, J. S., Baker, S. R., Patel, R., Luk, L., & Castro, A., 3rd. (2013). The causes of medical malpractice suits against radiologists in the United States. *Radiology*, 266(2), 548–554.

Yavuz, D. G., & Sözen, D. T. (2013). Metabolik Kemik Hastalıkları Türkiye Endokrinoloji ve Metabolizma Derneği. *türkiye endokrinoloji ve metabolizma derneği*.

Yu, J. S., Yu, S. M., Erdal, B. S., Demirer, M., Gupta, V., Bigelow, M., ... & White, R. D. (2020). Detection and localisation of hip fractures on anteroposterior radiographs with artificial intelligence: proof of concept. *Clinical radiology*, 75(3), 237-e1.

Yurkova, I., & Wolf, L. (2011). Under-triage as a significant factor affecting transfer time between the emergency department and the intensive care unit. *Journal of Emergency Nursing: JEN: Official Publication of the Emergency Department Nurses Association*, 37(5), 491–496.

Zararsız, İ., Kaya, E., Savaş, N., Meydan, S., Davran, R., Tutanç, M., & Duru, M. (2009). Mustafa Kemal Üniversitesi Tayfur Ata Sökmen Tıp Fakültesi acil servise kırık nedeni ile başvuran hastalarda kırık dağılımı ve sıklığı.

Zümrüt, M. (2014). Acil Servise Başvuran Çocuklarda Kırıkların Epidemiyolojik Değerlendirmesi. Kocatepe Tıp Dergisi, 15(2), 142–146.

