

ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMLERİ İLE KEMİK KIRIKLARININ X-RAY
GÖRÜNTÜLERİ ÜZERİNDEN OTOMATİK TESPİTİ

Aran Mahdi Zen Alabdeen ZEN ALABDEEN

ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI
2024

Her hakkı saklıdır

TEZ ONAYI

Aran Mahdi Zen Alabdeen ZEN ALABDEEN tarafından hazırlanan “**Derin Öğrenme Yöntemleri ile Kemik Kırıklarının X-ray Görüntüleri Üzerinden Otomatik Tespiti**” adlı tez çalışması 23/05/2024 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar Mühendisliği Anabilim Dalında **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Seda ŞAHİN

Jüri Üyeleri :

Başkan : Dr. Öğr. Üyesi Mustafa TEKE
Elektrik ve Elektronik Mühendisliği Anabilim Dalı
Çankırı Karatekin Üniversitesi

Üye : Dr. Öğr. Üyesi İbrahim ŞANLIALP
Bilgisayar Mühendisliği Anabilim Dalı
Kırşehir Ahi Evran Üniversitesi

Üye : Dr. Öğr. Üyesi Seda ŞAHİN
Elektronik ve Bilgisayar Mühendisliği Anabilim Dalı
Çankırı Karatekin Üniversitesi

Yukarıdaki sonucu onaylarım

Prof. Dr. Hamit ALYAR

Enstitü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğine göre hazırlamış olduğum “**Derin Öğrenme Yöntemleri ile Kemik Kırıklarının X-ray Görüntüleri Üzerinden Otomatik Tespiti**” konulu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, tezin Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü’nden başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve bu çalışmanın Çankırı Karatekin Üniversitesi tarafından kullanılan “Bilimsel İntihal Tespit Programı”yla tarandığını, “intihal içermediğini” beyan ederim. Çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması halinde ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm. Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim (23/05/2024).

Aran Mahdi Zen Alabdeen ZEN ALABDEEN

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME YÖNTEMLERİ İLE KEMİK KIRIKLARININ X-RAY GÖRÜNTÜLERİ ÜZERİNDEN OTOMATİK TESPİTİ

Aran Mahdi Zen Alabdeen ZEN ALABDEEN

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Elektronik ve Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Seda ŞAHİN

Bu tez, röntgen görüntülerinden kemik kırıklarını tespit etmek için özelleştirilmiş beş gelişmiş evrişimli sinir ağı (CNN) mimarisi üzerine detaylı bir karşılaştırmalı analiz sunmaktadır. Özellikle, bu çalışma Xception-FracAtlas, VGG16-FracAtlas, ResNet50-FracAtlas, InceptionV3-FracAtlas ve EfficientNetv2b2-FracAtlas performanslarını, Kırık ve Kırıksız olarak belirgin şekilde kategorize edilmiş bir veri seti kullanarak incelemektedir. Bu modeller, kesinlik, hatırlatma, F1-puanı, genel doğruluk ve çıkarım süresi gibi metrikler üzerinden değerlendirilerek, tıbbi görüntü analizindeki yetenekleri ve sınırlılıkları hakkında bütünsel bir görünüm sunmaktadır. EfficientNetv2b2-FracAtlas, çoklu metriklerde olağanüstü performans sergileyerek üstün model olarak öne çıkmıştır. Özellikle, %94.91 ile en yüksek doğruluk oranına ve Kırık durumlarını belirlemede güçlü kesinlik gösteren etkileyici bir F1-puanına ulaşmıştır. Ayrıca, 3 saniye 98 milisaniye ile en hızlı çıkarım süresini ve %80 eğitim ve %20 test değerleri ile 0.95 en yüksek ROC değerini kaydetmiştir. Bu sonuçlar, klinik ortamlarda kritik bir gereksinim olan gerçek zamanlı, doğru tıbbi teşhis potansiyelini vurgulamaktadır. Diğer modeller de umut verici sonuçlar göstermişken, tüm metriklerde uniform bir performans sergilemediler. Örneğin, VGG16-FracAtlas, Kırıksız durumlar için hatırlatma oranında başarılı olmuş ve hızlı çıkarım süreleri göstermiş fakat benzer doğruluk oranlarına veya F1-puanlarına ulaşamamıştır. Benzer şekilde, Xception-FracAtlas ve ResNet50-FracAtlas belirli metriklerde yetkinlik göstermiş ancak EfficientNetv2b2-FracAtlas tarafından sergilenen her yönüyle etkinliği sağlamada yetersiz kalmışlardır. EfficientNetv2b2-FracAtlas'ı klinik iş akışlarına entegre ederek, sağlık hizmet sağlayıcıları kemik kırığı tespitindeki hızı ve doğruluğu artırabilir, yanlış teşhis oranını azaltabilir ve daha hızlı tedavi tepkilerini kolaylaştırabilir.

2024, 57 sayfa

ANAHTAR KELİMELER: Derin öğrenme, Kemik kırığı tespiti, X-ışını görüntüleme, Evrişimli sinir ağları, Transfer öğrenimi

ABSTRACT

Master of Science Thesis

AUTOMATED DETECTION OF BONE FRACTURES OVER X-RAY IMAGES WITH DEEP LEARNING METHODS

Aran Mahdi Zen Alabdeen ZEN ALABDEEN

Çankırı Karatekin University
Graduate School of Natural and Applied Sciences
Department of Electronics and Computer Engineering

Advisor: Asst. Prof. Dr. Seda ŞAHİN

This thesis presents a detailed comparative analysis of five advanced convolutional neural network (CNN) architectures tailored for the detection of bone fractures from X-ray images. Specifically, the study examines the performance of Xception-FracAtlas, VGG16-FracAtlas, ResNet50-FracAtlas, InceptionV3-FracAtlas, and EfficientNetv2-FracAtlas, utilizing a dataset distinctly categorized into Non-Fractured and Fractured states. These models are evaluated based on precision, recall, F1-score, overall accuracy and inference time, offering a holistic view of their capabilities and limitations in medical image analysis. EfficientNetv2b2-FracAtlas emerged as the superior model, demonstrating exceptional performance across multiple metrics. Notably, it achieved the highest accuracy rate of 94.91% and an impressive F1-score which indicates its strong precision in identifying Fractured states. Moreover, it recorded the fastest inference time of 3 second 98 millisecond and the highest ROC value of 0.95 according to the 80% training and 20% testing values. These results highlight its potential for real-time, accurate medical diagnostics, a critical requirement in clinical settings. In contrast, while the other models also showed promising results, they did not perform uniformly across all metrics. For instance, VGG16-FracAtlas excelled in recall for Non-Fractured states and demonstrated rapid inference times but did not achieve comparable accuracy or F1-scores. Similarly, Xception-FracAtlas and ResNet50-FracAtlas showed proficiency in certain specific metrics but fell short in achieving the all-around effectiveness exhibited by EfficientNetv2-FracAtlas. By integrating EfficientNetv2-FracAtlas into clinical workflows, healthcare providers can enhance the speed and accuracy of bone fracture detection, potentially reducing the rate of misdiagnosis and facilitating faster treatment responses.

2024, 57 pages

Keywords: Deep learning, Bone fracture detection, X-ray imaging, Convolutional neural networks, Transfer learning

ÖNSÖZ VE TEŞEKKÜR

Yüksek lisans derecesi, ileri akademik araştırma yolculuğumun sonu değil, başlangıcıdır. Bu tez, profesyonel ve kişisel gelişimimde önemli bir dönüm noktasını temsil etmekte ve alanımdaki gelecekteki çabalarım için zemin hazırlamaktadır.

Bu tezi tamamlamamdaki destekleri vazgeçilmez olan birçok kişiye minnettarlığımı borç biliyorum. Her şeyden önce, tez danışmanım Dr. Öğr. Üyesi Seda ŞAHİN'e en derin teşekkürlerimi sunuyorum. Araştırma sürecindeki zorlukları aşmada gösterdiği sabır, anlayış ve değerli yönlendirmeleri son derece önemli olmuştur. Ayrıca, değerli desteği ve tavsiyeleri için Yüksek Mühendis Ethar Sulaiman Yaseen YASEEN'e de müteşekkirim. Pratik içgörülerini ve teşvikleri, bu araştırma süreci boyunca hayati öneme sahipti. Kişisel teşekkürlerimi aileme bilgeliğinin ışığı olan babama, kapasiteme olan inancıyla bana hiçbir zaman destek olmaktan vazgeçmeyen eşime; ve mükemmelliği hedeflemem için beni ilhamlandıran çocuklarıma sunarım. Bu tez, onlara adanmıştır, çünkü onlar sürekli motivasyon ve neşe kaynağım olmuşlardır.

Aran Mahdi Zen Alabdeen ZEN ALABDEEN

Çankırı, Mayıs 2024

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	ii
ÖNSÖZ VE TEŞEKKÜR.....	iii
İÇİNDEKİLER	iv
KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ.....	1
1.1 Çalışma Konusu	1
1.2 Araştırma Soruları	2
1.3 Amaç ve Kapsam	3
1.4 Çalışmanın Organizasyonu.....	4
2. LİTERATÜR TARAMASI.....	5
3. GENEL BİLGİLER	10
3.1 Makine Öğrenimi.....	13
3.1.1 Denetimli öğrenme.....	13
3.1.2 Denetimsiz öğrenme	14
3.1.3 Yarı denetimli öğrenme.....	15
3.1.4 Takviyeli öğrenme	16
3.2 Derin Öğrenme	16
3.2.1 Evrimsel sinir ağları	18
3.2.2 Tekrarlayan sinir ağları.....	19
3.2.3 Üretken rekabet ağları	20
3.2.4 Otokodlayıcı	21
3.3 Görüntü İşleme	22
4. MATERYAL VE YÖNTEM	24
4.1 Veri Seti	25
4.2 Ön İşleme.....	26
4.3 Önerilen Modeller.....	27
4.3.1 Xception.....	27

4.3.2 VGG16.....	28
4.3.3 ResNet50.....	29
4.3.4 InceptionV3.....	31
4.3.5 EfficientNet.....	32
4.4 Modellerin Performansının Değerlendirilmesi.....	33
4.4.1 Doğruluk.....	33
4.4.2 Hassasiyet.....	34
4.4.3 Duyarlılık.....	34
4.4.4 Hassasiyet ve duyarlılığın dengelenmesi.....	34
5. BULGULAR VE TARTIŞMA	36
5.1 Bilgisayar Sistem Konfigürasyonu.....	36
5.2 Xception-FracAtlas Sonuçları	36
5.3 VGG16-FracAtlas'ın Sonuçları.....	38
5.4 ResNet50-FracAtlas Sonuçları	39
5.5 InceptionV3-FracAtlas'ın Sonuçları.....	42
5.6 EfficientNet v2b2-fracAtlas'ın Sonuçları	44
5.7 Tartışma	47
5.8 Çalışmanın Sonuçlarının Önceki Çalışmalarla Karşılaştırılması.....	49
6. SONUÇ VE ÖNERİLER	51
KAYNAKLAR	52
ÖZGEÇMİŞ.....	57

KISALTMALAR DİZİNİ

DCNN	Derin evriřimli sinir aęlarının
DL	Derin öğrenme
SVM	Destek vektör makineleri
CNN	Evriřimsel sinir aęları
ML	Makine öğrenme
RL	Takviyeli öğrenme
RNN	Tekrarlayan sinir aęları
GAN	Üretken karřıt aęlar
AI	Yapay zeka



ŞEKİLLER DİZİNİ

Şekil 1.1 Çalışmanın Organizasyonuna İlişkin Akış Şeması	4
Şekil 3.1 Kemik kırığı türleri (Dev 2022)	11
Şekil 3.2 Çeşitli Kemik Kırığı Temelli X-ray (Bagaria ve diğerleri 2021)	12
Şekil 3.3 Makine öğrenmesinin türleri	13
Şekil 3.4 Derin öğrenme türü	17
Şekil 3.5 Mimari CNN tabanlı kemik fraksiyonları (Rahman <i>et al.</i> 2020)	18
Şekil 3.6 RNN'nin temel mimarisi (Khuong 2020)	19
Şekil 3.7 GAN temelli kemik fraksiyonları	20
Şekil 3.8 Otoenkoderler (Stewart 2020)	21
Şekil 4.1 Önerilen çalışmanın akış diyagramı	24
Şekil 4.2 Örnek veri seti	26
Şekil 4.3 Veri setinin hazırlanması (Abedein <i>et al.</i> 2023)	26
Şekil 4.4 Xception akış şeması diyagramı (Chollet 2017)	28
Şekil 4.5 VGG16 mimarisi (Boesch 2021)	29
Şekil 4.6 ResNet50 mimarisi (Kundu 2023)	30
Şekil 4.7 Inception V3 mimarisi (Google 2018)	31
Şekil 4.8 EfficientNet mimarisi (Mingxing 2019)	33
Şekil 5.1 Xception-FracAtlas'ın karışıklık matrisi	36
Şekil 5.2 Xception-FracAtlas için ROC	37
Şekil 5.3 VGG16-FracAtlas için karışıklık matrisi	38
Şekil 5.4 VGG16-FracAtlas için ROC	39
Şekil 5.5 ResNet50-fracatlas için karışıklık matrisi	40
Şekil 5.6 ResNet50-FracAtlas için ROC	42
Şekil 5.7 InceptionV3'ün karışıklık matrisi	43
Şekil 5.8 InceptionV3-FracAtlas için ROC	44
Şekil 5.9 EfficientNetV2b2 için karışıklık matrisi	45
Şekil 5.10 EfficientNetV2b2-FracAtlas için ROC	47
Şekil 5.11 Değerlendirilen sonuçları göstermektedir (Eğitimde %60, testte %40) doğruluk oranı	48
Şekil 5.12 Değerlendirilen sonuçları göstermektedir (Eğitimde %80, testte %20) doğruluk oranı	49

ÇİZELGELER DİZİNİ

Çizelge 5.1 %60-%40 Xception-FracAtlas Sonuçları.....	37
Çizelge 5.2 %80-%20 Xception-FracAtlas Sonuçları.....	37
Çizelge 5.3 %60-%40 VGG16-FracAtlas Sonuçları.....	38
Çizelge 5.4 %80-%20 VGG16-FracAtlas Sonuçları.....	39
Çizelge 5.5 %60-%40 ResNet50-FracAtlas sonuçları	41
Çizelge 5.6 %80-%20 ResNet50-FracAtlas sonuçları	41
Çizelge 5.7 %60-%40 InceptionV3-FracAtlas sonuçları	43
Çizelge 5.8 %80-%20 InceptionV3-FracAtlas sonuçları	44
Çizelge 5.9 %60-%40 EfficientNetV2b2-FracAtlas sonuçları	46
Çizelge 5.10 %80-%20 EfficientNetV2b2-FracAtlas sonuçları	46
Çizelge 5.11 %60-%40 ve %80-%20 FracAtlas'ta değerlendirilen sonuçlar	48

1. GİRİŞ

Röntgen görüntülemesi, kemik kırıklarını görselleştirmek ve değerlendirmek amacıyla ortopedik teşhislerde hayati bir araçtır. Ancak, bu aracın doğruluğu yorumlayan radyologun veya doktorun uzmanlığına göre değişebilmektedir (Tanzi *et al.* 2020). Derin öğrenme (DL) yöntemleri, röntgen görüntülerindeki kırık tespitini otomatikleştirerek bir çözüm sunmaktadır. Bu algoritmalar, yüksek hassasiyet ve verimlilikle görüntüleri analiz edebilmekte, tanı doğruluğunu ve iş akışı verimliliğini artırmaktadır (Badgeley *et al.* 2019). Yapılan çalışmalar, DL yöntemlerinin, sınırlı bir eğitim görüntü setiyle bile, insan uzmanları geçerek kırık tespitinde önemli ölçüde daha yüksek doğruluk oranlarına ulaşabildiğini göstermektedir. Ayrıca, bu modeller, özellikle deneyimsiz genç radyologların gözden kaçırabileceği pediatrik yaylanma kırıkları gibi belirli kırık türlerini tespit edebilmektedir. Kemik kırığı tespitinde derin öğrenmenin entegrasyonu, teşhis oranlarını ve hasta bakımını iyileştirme vaadinde bulunmakta, yanlış teşhisleri, gereksiz radyasyon maruziyetini ve cerrahi işlemleri azaltmaktadır. Tanısal görüntü analizinde yeni standartlar belirleyen DL ile radyologların gelecekteki rolü üzerine devam eden bir tartışma bulunmaktadır. Bazıları, makine öğreniminin radyologların daha fazla vaka ile ilgilenmelerini sağlayabileceğini veya tanı sorumluluklarını bu sistemler tarafından desteklenen radyolog olmayan kişilere devretmelerine olanak tanıyabileceğini öne sürmektedir. Yapay zeka, özellikle DL algoritmalarının ilerlemesi, tıbbi görüntü analizini dönüştürme potansiyeline sahiptir. Bu çalışma, evrimsel sinir ağlarını kullanarak röntgen görüntülerinde kesin kırık tespiti ve sınıflandırması için DL tabanlı bir sistem geliştirmeyi araştırmaktadır. Böyle bir sistem, yanlış teşhisleri ve hasta üzerindeki olumsuz sonuçları, uzun süreli rahatsızlıklar ve gereksiz cerrahiler dahil, önemli ölçüde azaltabilir. DL ile kırık tespitinin otomatikleştirilmesi, klinik uzmanlara olan bağımlılığı azaltabilir, tanı ve yönetim verimliliğini iyileştirebilir.

1.1 Çalışma Konusu

Mevcut tanı süreçleri, kemik kırıklarını tespit etmedeki zorlukları ve eksiklikleri ele almaktadır. Tıbbi görüntüleme teknolojilerindeki ilerlemelere rağmen, kemik kırıklarının tespiti ve tanısı büyük ölçüde radyologların ve klinik çalışanlarının uzmanlığına

dayanmaktadır; bu kişiler röntgen görüntülerini manuel olarak yorumlamaktadır. Bu yaklaşım zaman alıcı, öznel ve insan hatasına açık olabilir, bu da potansiyel yanlış tanıları veya gözden kaçan kırıkları getirebilir. Ele alınan başlıca sorunlar arasında tanı doğruluğu ve tutarlılığı, zaman kısıtlamaları, kaynak sınırlamaları ve ince kırıklar ile karmaşık vakalar yer almaktadır. Röntgen görüntülerinin manuel yorumlanması klinikçiler arasında önemli ölçüde farklılık gösterebilir; bu da tanı doğruluğunu ve tutarlılığını etkileyerek hasta tedavisinde farklılıklara yol açabilir. Zaman kısıtlamaları, özellikle kaynakları kısıtlı veya kırsal alanlardaki hastaların gerekli tedavileri alma hızını etkileyebilir.

Bu çalışma, tıbbi görüntülemelerde DL yöntemlerini kullanarak kemik kırıklarını otomatik olarak tespit etmeyi amaçlamaktadır. Kemik kırığı tespiti için derin öğrenmenin kullanılması, bakım noktasında doğru ve zamanında tespit ve tanıları sağlamakta, tanı ve tedaviyi büyük ölçüde iyileştirmektedir. Bu, hem hastalar hem de klinik çalışanlar için faydalı olmakta, daha hızlı tedavilerin kilidini açmakta ve yanlış tanı ihtimallerini azaltmaktadır. DL algoritmaları, büyük veri setlerinde eğitilmekte ve farklı görüntü setlerine uygulanmaktadır, bu da bu çalışmadan elde edilen ilerlemelerin ve bilgilerin çeşitli klinik bağlamlarda, kaynakları kısıtlı ortamlar dahil uygulanmasına olanak tanımaktadır. Ancak, klinik denemelerde iyi performans göstermekte ve gerçek hasta bakım senaryolarında derin öğrenmeyi etkili bir şekilde kullanacak algoritmalar oluşturulmakta ve doğrulanmaktadır. Otomatik kırık tespiti için DL algoritmasının titiz geliştirilmesi ve test edilmesi, bu yeni alanda doğrulanmış ve etkili bir yöntem katkıda bulunmakta, tıbbi görüntülemelerde DL için sağlam bir bilgi tabanı oluşturmakta ve DL algoritmalarının tıbbi görüntüleri yorumlama etkinliğini gösteren literatürü artırmaktadır.

1.2 Araştırma Soruları

Bu çalışmadaki araştırma soruları şunlara odaklanmaktadır:

- X-ray görüntülerinden kemik kırıklarını tespit etmede transfer öğrenme yöntemleri hassasiyet, hatırlama oranı ve F1 skoru açısından nasıl karşılaştırılır?

- X-ray görüntülerinde kırıklı ve kırıksız durumları ayırt etmede uygulanan transfer öğrenme yöntemleri arasında genel doğruluk oranlarında ne gibi farklar vardır?
- Kemik kırığı tespiti için X-ray görüntülerinde kullanılan transfer öğrenme yöntemlerinin çıkarım süreleri nasıl değişmektedir?
- Her bir evrişimli sinir ağı (CNN) mimarisi (Xception, VGG16, ResNet50, InceptionV3, EfficientNetv2b2) kemik kırığı tespiti görevlerindeki performansları açısından hangi güçlü ve zayıf yönleri vardır?
- Önerilen transfer öğrenme yöntemlerinin X-ray görüntülerinde kırıklı ve kırıksız durumları ayırt etme yeteneği açısından alıcı işletim karakteristik (ROC) eğrileri nasıl farklılık göstermektedir?
- Bu karşılaştırmalı analizden elde edilen bulgular, kemik kırığı tespiti dışındaki tıbbi görüntüleme görevlerinde performansı artırmak için evrişimli sinir ağı mimarilerinin optimizasyonuna nasıl katkı sağlayabilir?

DL modellerinin klinik ortamlarda benimsenmesi, kemik kırığı tanısı bağlamında hasta bakımı, tedavi sonuçları ve sağlık hizmeti sunumunun genel verimliliği üzerinde nasıl bir etki yapabilir?


1.3 Amaç ve Kapsam

Bu araştırma, röntgen görüntülerinde kemik kırıklarını tespit etmek için DL yöntemlerine dayalı otomatik bir sistem geliştirmeyi, uygulamayı ve doğrulamayı amaçlamaktadır. Sistem, radyologlara ve klinik çalışanlara güvenilir, doğru ve hızlı bir araç sağlayarak tanı sürecini geliştirmeyi amaçlamaktadır. Araştırma, çeşitli hasta popülasyonları ve çeşitli kırık türlerinde kemik kırıklarını doğru bir şekilde tanımlayıp yerleştirebilen DL modellerinin tasarımı ve eğitimi üzerine odaklanmaktadır. Bu modellerin performansı, iyi hazırlanmış bir röntgen görüntüsü veri seti üzerinde doğruluk, duyarlılık, özgüllük ve alıcı işletim karakteristiği eğrisi (AUC-ROC) altında alan gibi standart metrikler kullanılarak değerlendirilmektedir. Araştırma, veri toplama ve hazırlama, algoritma geliştirme, model doğrulama gibi çeşitli kapsamları içermektedir. Veri toplama, kapsamlı ve çeşitli bir röntgen görüntüsü veri seti edinmeyi içerirken, algoritma geliştirme, kırık tespiti için CNN'ler gibi DL algoritmalarının tasarımı ve optimizasyonunu

içermektedir. Model doğrulama, güvenilirlik ve genelleştirilebilirlik sağlamak için bağımsız test setleri üzerinde kapsamlı bir doğrulama içermektedir. Bu çalışma, açık hedefler ve kapsamlar belirleyerek tıbbi görüntüleme ve tanı alanına önemli katkılarda bulunmayı ve klinik uygulamada kemik kırığı tespitinin doğruluğunu, verimliliğini ve erişilebilirliğini artıran yenilikçi bir çözüm sunmayı amaçlamaktadır.

1.4 Çalışmanın Organizasyonu

Çalışmanın yapısı Şekil 1.1'de gösterilmektedir.



Şekil 1.1 Çalışmanın Organizasyonuna İlişkin Akış Şeması

2. LİTERATÜR TARAMASI

Bilgisayarların, sağlık hizmetleri dahil olmak üzere günlük yaşamın çeşitli yönlerine entegrasyonu, bu alanlarda verimliliği ve erişilebilirliği önemli ölçüde artırmaktadır. Özellikle sağlık hizmetlerinde, teknolojik yenilikler X-ray tarayıcıları gibi tanı araçlarında büyük iyileştirmeler sağlamaktadır. Bu alandaki dikkate değer bir ilerleme, X-ray görüntülerinden kemik kırıklarının tespiti için makine öğrenimi algoritmalarının uygulanmasıdır. Son çalışmalara göre, Naive Bayes, Karar Ağacı, En Yakın Komşular, Rastgele Orman ve Destek Vektör Makineleri (SVM) gibi algoritmalar, %64 ile %92 arasında değişen doğruluk seviyelerini gösteren 270 X-ray görüntüsünü kapsayan bir veri setinde kullanılmaktadır. En yüksek doğruluk SVM için bildirilmiş, ardından Rastgele Orman, En Yakın Komşular, Karar Ağacı ve Naive Bayes takip etmektedir (Dlshad and Hawezi 2023).

Sahin (2023), ortopedide kırıkların tanımlanması ve kategorize edilmesine yönelik olarak makine öğrenimi tekniklerinin uygulanmasına odaklanmaktadır. Veri seti, normal ve hasarlı kemikleri içermekte olup, X-ray görüntüleri görüntü ön işleme ve özellik çıkarma işlemlerinden geçmektedir. Çalışma, en iyi hiperparametreleri belirlemek için ızgara arama yöntemini kullanarak 12 farklı makine öğrenimi sınıflandırıcısını analiz etmektedir. Araştırma, 10 katlı çapraz doğrulama kullanılarak yapılmış olup, Doğrusal Diskriminant Analizi'nin en yüksek doğruluk oranını %88.67 ve Eğri Altında Alan değerini 0.89 olarak elde ettiğini ortaya koymuştur. Bilgisayar destekli tanı sistemi, kırıkları doğru bir şekilde teşhis ederek doktorların iş yükünü azaltmayı ve tanı ve tedavide doğrudan katılımlarının ihtiyacını azaltmayı hedeflemektedir.

Su *et al.* (2023), tanıma, sınıflandırma, tespit ve lokalizasyon görevleri için tanımlanmamış terimler gibi zorlukları ele alarak iskelet kırıklarını teşhis etmek için DL modellerinin kullanımını araştırmaktadır. 337 makaleden 40'ını gözden geçirerek, DL bağlamında kemik kırığı tanıma, sınıflandırma, tespit ve lokalizasyonun tanımlarını netleştirmektedir. İnceleme ayrıca her çalışmanın özetini, incelenen kemikler, hedefler, veri seti büyüklükleri, metodolojiler, sonuçlar ve sonuçlar üzerine odaklanarak sunmaktadır. Gelecek araştırma yönleri, ağ yorumlanabilirliğini iyileştirmek, çok modlu

klirik verileri dahil etmek, tedavi planı önerileri sunmak ve klinik kullanım için sofistike grselleřtirme tekniklerini geliřtirmek olarak belirlenmiřtir.

Ju ve Cai (2023), pediatrik bilek travması X-ray veri seti (GRAZPEDWRI-DX) zerinde kırık tespiti iin YOLOv8 algoritmasının performansını iyileřtirmeye odaklanmaktadır. Model, iyileřtirilmiř YOLOv7 ve orijinal YOLOv8 modellerinden nemli lde daha yksek olan 0.638 ortalama doęruluk (mAP 50) elde etmektedir. Arařtırmacılar, cerrahların X-ray grntlerinde kırıkları teřhis etmelerine yardımcı olmak iin YOLOv8 Uygulaması Kullanarak kırık Tespiti adında bir uygulama tasarlamıřtır. Bu ilerleme, bilgisayarlı grde DL, kırık tespiti alanında nemli bir arařtırma konusu haline gelmektedir.

Guan *et al.* (2022), DL yoluyla uyluk kemięi kırıklarını tespit etmek iin yeniliki, iki ařamalı, blge tabanlı bir evriřimli sinir aęı sunmaktadır. Aę, zellik haritası bilgilerini ResNeXt'in zellik piramidi boyunca eřit olarak daęıtmaktadır. Model, 3.842 uyluk kemięi X-ray grntsn ieren bir veri seti kullanılarak deęerlendirilmektedir. Transfer ęrenimi, ereveyi kurulu tanı yntemleriyle karřılařtırmak iin kullanılmaktadır. Ablasyon testleri, kırık tespitindeki bireysel bileřenlerin ve hiperparametre yapılandırılmalarının etkisini gstermektedir. Sonular, uyluk kemięi kırıklarını tespit etmede %88,9 Ortalama Hassasiyet saęlamakta, nerilen erevenin etkinlięini ve mevcut keskin kenarlı yaklařımlara stnlęn doęrulamaktadır.

Hardala vd. (2022), zellikle acil durumlar iin klinik alıřanların bilek kırıklarını tespit etmesine ve tedavi etmesine yardımcı olmak iin bilek X-ray grntleri zerinde DL algoritmalarını kullanmaktadır. Bilek kırığı teřhis grevlerini gerekleřtirmek iin birden fazla DL nesne tespit modeli kullanılmaktadır. Beř toplu model geliřtirilmiř ve 'Bilek Kırığı Tespiti-Kombo (WFD-C)' adında benzersiz bir tespit modeli oluřturmak iin iyileřtirilmiřtir. WFD-C modeli, 0.8639 ortalama doęruluk (AP50) ile maksimum tespit sonucu elde etmektedir.

Khatik ve Kadam (2022), dijital X-ray'leri analiz ederek kemik kırıklarını otomatik olarak teřhis etmek iin makine ęrenimi kullanmaktadır. Bilgisayar grř alanında yaygın

olarak kullanılan bir teknik olan CNN (Evrişimli Sinir Ağları) bu çalışmada kullanılmaktadır. Çalışma, PRISMA kriterlerine uygun olarak mevcut CNN yöntemlerini kemik kırığı teşhisinde incelemektedir. Sonuçlar, çeşitli kemik türlerindeki kırıkları tespit etmek için tek bir yöntemin olmadığını göstermektedir. Mevcut makine öğrenimi yetenekleri, tüm kemik kırıkları türlerini ele alacak genel bir yaklaşım sunmamaktadır. Bu sorunu aşmak için, birden fazla CNN yöntemi, birleşik hibrid bir boru hattına senkronize edilebilir.

Ashkani-Esfahani *et al.* (2022), ayak bileği kırıklarını radyografik görüntülerden tespit etmede Inception V3 ve ResNet-50 olmak üzere iki derin evrişimli sinir ağı (DCNN)'nın doğruluğunu karşılaştırmaktadır. Ağlar, Danis-Weber sınıflandırma sistemini kullanarak ayak bileği yaralanmaları olan ve olmayan 1050 hasta üzerindeki bir veri setinde eğitilmektedir. Çalışma, üç görüntülü radyografileri analiz ederken DCNN'lerin, özellikle Inception V3 modeli ile daha iyi performans gösterdiğini bulmaktadır. Bu, özellikle çok görüntülü resimler üzerinde eğitildiğinde, DCNN'lerin ayak bileği kırığı tespit doğruluğunu ve verimliliğini artırabileceğini öne sürmektedir. Bu ağlar, gelişmiş görüntü yorumlama araçları geliştirmek veya sağlık hizmeti uzmanlarına tanı yardımcısı olarak kullanılmak üzere temel bileşenler olarak kullanılabilir, daha hızlı ve daha doğru kırık tespiti sağlamak için kolaylık sağlamaktadır.

Bagaria *et al.* (2021) tarafından sunulan, X-ray görüntüleme yoluyla kemik bozukluklarının erken tespiti ve ayrımı için DL tekniklerini kullanan yenilikçi bir yaklaşım sunulmaktadır. Bu yaklaşımın merkezinde, kırık olmuş kemikler ile herhangi bir yaralanması olmayanları ayırt etmek için tasarlanmış bir CNN modeli kullanılmaktadır. Araştırma, modelin performansını optimize etmek için dönemler, grup boyutu, iyileştiriciler ve öğrenme oranı gibi çeşitli parametreleri titizlikle araştırmaktadır. Modelin etkinliği, %89,8 özgüllük, %90 doğruluk ve alıcı işletim karakteristiği (ROC) eğrisi altında 0,8 alan elde etmesiyle kanıtlanmaktadır. Bu metrikler, modelin kemik kırıklarını doğru bir şekilde tespit etme kapasitesini vurgulamakta ve tıbbi görüntüleme ve tanı alanında önemli bir ilerleme olarak işaret etmektedir.

Nguyen *et al.* (2021), kol kemiklerinin X-ray görüntülerindeki kırıkları tanımlamak için DL yaklaşımı sunmaktadır. Bu yaklaşım, görüntü segmentasyonu için YOLACT++ ile görüntü kontrastını artırmak için Kontrast Sınırlı Uyarlamalı Histogram Eşitleme'yi birleştirmektedir. Algoritma, dört veri artırma stratejisi kullanılarak küçük bir veri seti üzerinde eğitilmektedir. Elde edilen en yüksek sonuç %81.91 olup, sınırlı veri setindeki Daha Hızlı R-CNN tabanlı çözümden daha üstündür. Bu yeni yöntem, kol kırığına bağlı yaralanmaları azaltmada hayati öneme sahiptir.

Tanzi *et al.* (2020), kemik kırıklarını sınıflandırmak için DL tekniklerinin kullanımını inceleyerek, araştırma makaleleri seçimine odaklanmaktadır. Her yaklaşımın güçlü yönlerini vurgulamak ve DL yöntemleri kullanılarak genel bir kemik kırığı sınıflandırma stratejisi geliştirmek amaçlanmaktadır. Değerlendirme, alan altında eğri, test doğruluğu, duyarlılık, özgüllük, veri seti büyüklüğü ve etiketleme güvenilirliği gibi anahtar metrikleri ölçen bir radar grafiği üzerinden yapılmaktadır. Çalışma, özellikle CNN'lerin, kemik kırığı sınıflandırmasında insan uzmanlarına benzer performans seviyelerine ulaşan başarılarını vurgulamaktadır. Son hedef, iyi tasarlanmış bir bilgisayar destekli tanı sisteminin, zaman tasarrufu sağlayarak ve yanlış teşhis oranlarını azaltarak doktorlara önemli ölçüde yardımcı olabileceğini göstermektir.

Thian vd. (2019), bilek radyografilerinde kırıkları tespit etmek ve yerlerini belirlemek için bir CNN kullanmanın uygulanabilirliğini ve etkinliğini göstermektedir. Toplam 7,356 bilek radyografi çalışması bir hastanenin resim arşivleme ve iletişim sisteminden alınmıştır. Radyologlar tüm radius ve ulna kırıklarını sınırlayıcı kutular ile işaretlemiştir. Veri seti eğitim ve doğrulama setlerine bölünmüş, kırık lokalizasyon modelleri Inception-ResNet Daha Hızlı R-CNN mimarisi kullanılarak eğitilmiştir. Modeller, daha önce görülmemiş 524 acil servis bilek radyografi çalışması üzerinde değerlendirilmiştir. Bulgular, modelin radius kırıklarının 310'unu 340'tan (%91.2) ve ulna kırıklarının 236'sını 245'ten (%96.3) hem ön hem de yan görünümde doğru bir şekilde tespit ettiğini göstermiştir. Ön görünüm için, görüntü başına duyarlılık, özgüllük ve AUC sırasıyla %95.7, %82.5 ve 0.918'dir. Yan görünüm için bu değerler sırasıyla %96.7, %86.4 ve 0.933'tür. Her çalışma için duyarlılık, özgüllük ve AUC sırasıyla %98.1, %72.9 ve 0.895'tir.

Bu çalışma, X-ray görüntülerinden kemik kırıklarının otomatik tespiti için DCNN uygulamasını iletirmektedir. İyileştirilmiş tespit doğruluğu göstermekte, potansiyel olarak tanı hatalarını azaltmakta ve hasta sonuçlarını iyileştirmektedir. Çalışma ayrıca, farklı DCNN mimarilerinin karşılaştırmalı bir analizini sunmakta, hesaplama kaynaklarının optimizasyonu ve tanı hızı için en verimli modelleri belirlemektedir. DCNN modellerinin uygulanması, tıbbi görüntülemelerde DLnin uygulanmasıyla ilgili zorluklara ve düşünülmesi gereken noktalara pratik içgörüler sağlamaktadır; bu, veri ön işleme, model seçimi, eğitim stratejileri ve veri seti değişkenliğinin etkisini içermektedir. Bulgular, gelecek araştırmalar için bir referans olarak hizmet etmekte, model iyileştirmeleri, diğer tanı araçları ile entegrasyon ve diğer tıbbi görüntüleme türlerinde DL uygulamalarını keşfetme alanlarını önermektedir. Çalışma, klinik uygulamalara önemli bir etki yapma potansiyeline sahip olup, radyologların ve doktorların daha doğru ve zamanında tanımlar yapmalarına yardımcı olarak sonuçta hasta bakımını iyileştirmektedir. Genel olarak, bu çalışma, sağlık hizmetlerinde DL uygulamaları üzerine büyüyen bilgi birikimine katkıda bulunmaktadır.

3. GENEL BİLGİLER

Organik/inorganik maddelerden oluşan ve dayanıklı bir yapıya sahip olan kemik vücudun desteğini sağlamada en önemli organizmadır. İnsan vücudunda 206 kemik bulunmaktadır ve bu oran vücut kitlesinin %20'sini oluşturmaktadır. Dayanaklı olduğu kadar hafif bir yapıya sahip olan kemik fazla yüke maruz kaldığında çatlayabilmekte veya kırılabilmektedir. Ayrıca, kemik zayıflamasına yol açan osteoporoz gibi rahatsızlıklar ilerleyen yaşlarda kemiklerin kırılması ile sonuçlanmaktadır. Uluslararası Osteoporoz Vakfı (IOF) verilerine göre osteoporoz rahatsızlığının bayanlarda görülme riski %40-50 iken erkeklerden bu oran %13-22 arasındadır. Osteoporoz rahatsızlığının dışında düşme, spor yaralanmaları, trafik kazaları gibi nedenler kemik kırıklarına neden olabilmektedir. Yapılan bir araştırmada Amerika'da her yıl 6,8 milyon kişi kemik kırığı ile karşılaşmaktadır. Günümüzde, medikal cihaz teknolojilerinin gelişmesi ile beraber röntgen, bilgisayarlı tomografi gibi cihazlar kullanılarak kemik kırığı tespit edilebilmektedir. Doktorlar ya da radyologlar elde edilen x-ışını resimleri inceleyerek kemiklerin kırık olup olmadığı teşhisini koymaktadırlar. Ancak, belirlenmesi zor kırık veya çatlak tespitinde yanlış teşhis konulabilmekte ve bunun sonucunda hem doktorlar hem de hastalar zor durumda kalabilmektedir. Örneğin; yapılan bir çalışmada A.B.D'de her yıl 5 radyologdan bir tanesinin yanlış tedavi uyguladığı ve bu tedavilerin %40'na yanlış radyolojik teşhis durumlarının neden olduğu ve bu grubun da %40'nı tespit edilemeyen kırıklar olduğu vurgulanmaktadır. Yanlış teşhisin sonucunda hastaya yanlış tedavi yöntemleri uygulanabilmekte ve bundan dolayı tedavi süresi uzayabilmektedir. Son yıllarda biyomedikal alanında gerçekleştirilen birçok çalışmada çeşitli hastalıkların tespitini kolaylaştırmak için bilgisayar destekli teşhis sistemleri üzerine odaklanılmıştır. Bu çalışmalarda genellikle yanlış teşhis oranını düşürmek 2 hedeflenmektedir. Günümüzde mamogramda kitle teşhisi, göz hastalıkları, kanser teşhisi gibi birçok tıbbi uygulama alanında görüntü işleme tekniklerinin kullanımı oldukça artmıştır.

Yapay Zeka (AI), Makine Öğrenimi (ML) ve DL, X-ray görüntülerinde kemik kırıklarının otomatik tespitinde önemli ölçüde katkı sunmaktadır. AI, insan zekasını taklit ederek tanı doğruluğunu artırır, insan hatasını azaltır ve tutarlı tanı kriterlerini sağlar. ML algoritmaları, geniş veri setlerinde sağlıklı ve kırık kemikleri ayırt etmeye yardımcı olur,

zamanla tanı doğruluğunu artırır. Şekil 3.1, AI ve DL modellerinin X-ray görüntülerinden otomatik olarak tespit etmesi ve sınıflandırması gereken çeşitli kemik kırık türlerini göstermektedir (Dev 2022).



Şekil 3.1 Kemik kırığı türleri (Dev 2022)

DL, özellikle CNN'ler gibi sinir ağı mimarileri ile görüntü tanıma görevleri için özellikle uygundur. DL, X-ray görüntülerindeki karmaşık detayları analiz edebilir ve insan gözünün veya temel analitik yöntemlerin gözden kaçırabileceği ince kırık belirtilerini tespit edebilir. Bu düzeydeki analiz, zamanında ve uygun tedaviye yol açacak küçük veya karmaşık kırıkların tespiti için kritik öneme sahiptir. AI, ML ve DL'in X-ray görüntülerinde kemik kırıklarını tespit etmedeki entegrasyonu, tıbbi tanı alanında önemli bir ilerleme temsil etmektedir. AI destekli sistemler, radyologların nadir bulunduğu bölgelerde kritik tanı desteği sağlayabilir, coğrafi konumdan bağımsız olarak zamanında bakımı garanti eder (Meena and Roy 2022). Şekil 3.2, çeşitli kemik kırığı temelli X-ray görüntülerini göstermektedir (Bagaria *et al.* 2021).



Şekil 3.2 Çeşitli Kemik Kırığı Temelli X-ray (Bagaria vd. 2021)

Mevcut kırık tespit yöntemleri arasında fiziksel muayene, X-ray, bilgisayarlı tomografi, manyetik rezonans görüntüleme ve ultrason yer almaktadır. Fiziksel muayene, şişlik, morarma veya şekil bozukluğu gibi bir kırığın belirtilerini kontrol etmektedir. Radyografi, kırıkları görselleştirmek için en yaygın kullanılan tanı aracı olmaktadır; bilgisayarlı tomografi ise karmaşık kırıklar için daha detaylı görüntüler sağlamaktadır. Manyetik rezonans görüntüleme, hem kemikleri hem de yumuşak dokuları detaylı bir şekilde göstermekte ve X-ray'lerde görünmeyen stres kırıklarını tespit etmektedir. Ultrason, bazı özel bölgelerdeki veya pediatrik vakalarda kırıkları tespit etmek için bazen kullanılmaktadır. Yapay zeka ve DL teknolojileri, kırık tespitinde yeni bir sınır açmaktadır. Büyük, etiketli görüntü veri setleri üzerinde DL modelleri eğitilerek, algoritmalar insan radyologların kolayca fark edemediği ince kırık belirtilerini tanımayı öğrenmektedir (Su *et al.* 2023). Bu, başlangıç taramalarının doğruluğunu önemli ölçüde artırmakta ve tanı için gerekli zamanı azaltmaktadır. Ancak, yapay zeka araçları, tıbbi profesyonellerin kırıkların tanı ve tedavisinde uzmanlıklarını yerine geçmek yerine onlara yardımcı olmak için tasarlanmaktadır.

3.1 Makine Öğrenimi

ML, verilerden öğrenme üzerine kurulu sistemler geliştirmeye odaklanan yapay zekanın bir alt kümesidir. Bu sistemler, belirli bir görevi yerine getirmek üzere açıkça programlanmış olmaktan ziyade, deneyimlerden öğrenmeye ve gelişmeye yönelik tasarlanmaktadır. ML, bilgisayarların veri girişiyle "öğrenmesini" sağlamak için istatistiksel teknikler kullanmaktadır ve bu öğrenme süreci, bir algoritmanın doğrudan programlanmadan tahminlerde bulunabilmesi veya kararlar alabilmesi için eğitilmesini içermektedir (Nichols *et al.* 2018). Kırık tespiti bağlamında, ML algoritmaları, kırıklara işaret eden görüntüleme verilerindeki örüntüleri tanıyacak şekilde eğitilebilmektedir. Şekil 3.3'te gösterildiği gibi ML genellikle dört ana tipe ayrılmaktadır: Gözetimli Öğrenme, Gözetimsiz Öğrenme, Yarı Gözetimli Öğrenme ve Pekiştirmeli Öğrenme.



Şekil 3.3 Makine öğrenmesinin türleri

3.1.1 Denetimli öğrenme

Denetimli makine öğrenimi olarak da bilinen denetimli öğrenme, makine öğrenimi ve yapay zekânın bir alt kategorisidir. Verileri sınıflandırmak veya sonuçları doğru bir şekilde tahmin etmek için algoritmaları eğitmek için etiketlenmiş veri kümelerinin kullanılmasıyla tanımlanır. Denetimli öğrenme, modellere istenen çıktıyı verecek şekilde öğretmek için bir eğitim seti kullanır. Bu eğitim veri seti, modelin zaman içinde öğrenmesini sağlayan girdileri ve doğru çıktıları içerir. Algoritma, hata yeterince minimize edilene kadar ayar yaparak, kayıp fonksiyonu aracılığıyla doğruluğunu ölçer. Denetimli öğrenme, veri madenciliği sırasında iki tür probleme ayrılabilir: sınıflandırma

ve regresyon. Sınıflandırma, test verilerini belirli kategorilere doğru bir şekilde atamak için bir algoritma kullanır. Veri kümesi içindeki belirli varlıkları tanır ve bu varlıkların nasıl etiketlenmesi veya tanımlanması gerektiği konusunda bazı sonuçlar çıkarmaya çalışır. Regresyon, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi anlamak için kullanılır (Syed ve Lokhande 2024).

X-ray görüntülerinden kırık tespiti bağlamında gözetimli öğrenme özellikle yararlı olabilirdi. Kırıkların türü ve yeri ile etiketlenmiş X-ray görüntüleri veri kümesi, çeşitli kırık türlerini tanıyacak bir modeli eğitmek için kullanılmıştı. Eğitildikten sonra, model yeni X-ray görüntülerinde kırıkları tahmin edebilmiş, bu da tıbbi profesyonellere tanı konusunda yardımcı olmuş ve hastalar için zamanında tedavi sağlanmasını garantilemişti (Hardalaç vd. 2022).

3.1.2 Denetimsiz öğrenme

Denetimsiz makine öğrenimi olarak da bilinen denetimsiz öğrenme, etiketlenmemiş veri kümelerini analiz etmek ve kümelemek için makine öğrenimi algoritmalarını kullanır. Bu algoritmalar, insan müdahalesine ihtiyaç duymadan gizli kalıpları veya veri gruplamalarını keşfeder. Bilgilerdeki benzerlikleri ve farklılıkları keşfetme yeteneği, onu keşifsel veri analizi, çapraz satış stratejileri, müşteri segmentasyonu ve görüntü tanıma için ideal çözüm hâline getirir. Denetimsiz öğrenme, bilinen bir sonuç değişkeni veya ödül sinyali olmadan veri içerisindeki örüntüleri tanımlayan bir makine öğrenimi tekniğidir (Meena ve Suriya 2020). Denetimsiz öğrenmede ana kavramlar arasında kümeleme, boyut indirgeme ve ilişkilendirme yer almaktadır. Denetimsiz öğrenme türleri arasında, K-means, Hiyerarşik kümeleme ve DBSCAN gibi kümeleme algoritmaları, Apriori ve Eclat gibi ilişki kuralı öğrenme algoritmaları, özellik öğrenme, boyut indirgeme ve üretken modeller için Otoenkoderler gibi sinir ağları ve büyük değişken kümelerini daha küçüklerine dönüştürmek için Temel Bileşen Analizi (PCA) bulunmaktadır. Tıbbi görüntülemede, denetimsiz öğrenme, görüntü segmentasyonu, anomali tespiti ve özellik çıkarımı gibi alanlarda kullanılabilir. Örneğin, denetimsiz öğrenme algoritmaları X-ray görüntülerini analiz edebilir ve benzer özelliklere sahip kümelemeleri tanımlayabilir; bu kümelemeler farklı doku türleri veya

patolojilerle, kırıklar dahil, ilişkilendirilebilir. Denetimsiz öğrenme, bu kümelemeleri açıkça "kırıklar" olarak etiketlemese de, sağlık profesyonelleri tarafından daha fazla araştırma gerektiren anomalileri veya örüntüleri vurgulayabilir. Denetimsiz öğrenmedeki zorluklar ve düşünülmesi gereken hususlar arasında yorumlanabilirlik, sonuçların kalitesi ve veri kalitesine bağımlılık yer almaktadır. Etiketlerin olmaması, modellerin doğruluğunu veya buldukları örüntülerin önemini değerlendirmenin doğrudan bir yolunun olmadığı anlamına gelmektedir. Denetimsiz öğrenmenin başarısı, kullanılan verilerin kalitesine ve temsil yeteneğine büyük ölçüde bağlıdır. Sınırlamalarına rağmen, denetimsiz öğrenme, tıbbi görüntüleme verilerinde gizli yapıları veya özellikleri ortaya çıkarabilen güçlü bir keşif aracı olmaya devam etmektedir (Vermeulen 2019, McNicholas and Tait 2019).

3.1.3 Yarı denetimli öğrenme

Yarı denetimli öğrenme, hem etiketli hem de etiketsiz verilerin avantajlarını birleştiren bir makine öğrenimi yaklaşımıdır (Chen *et al.* 2020). Etiketleme maliyetinin yüksek veya zaman alıcı olduğu durumlarda ve yanında daha küçük bir etiketli veri seti bulunan büyük miktarda etiketsiz veri olduğunda kullanılmaktadır. Öğrenme algoritması, yalnızca etiketli verileri kullanarak mümkün olabileceğinden daha iyi bir model oluşturmak için hem etiketli hem de etiketsiz verileri kullanmaktadır. Yarı denetimli öğrenmede ana kavramlar arasında etiketli veriler (bilinen sonuçları veya etiketleri olan küçük bir alt küme) ve etiketsiz veriler (bilinmeyen sonuçları veya etiketleri olan daha büyük bir veri seti) yer almaktadır. Yarı denetimli öğrenme teknikleri arasında kendi kendine eğitim, ortak eğitim, dönüştürücü öğrenme ve grafik tabanlı yöntemler bulunmaktadır. Tıbbi görüntülemede, etiketli tıbbi verilerin kıtlığı nedeniyle yarı denetimli öğrenme oldukça değerli olabilmektedir (Gomes *et al.* 2022). Eğitim veri setinin etkin büyüklüğünü artırabilir, modelin genelleştirilmesini iyileştirebilir ve geniş etiketli veri setlerine olan ihtiyacı azaltabilir. Örneğin, yarı denetimli bir öğrenme algoritması, daha büyük bir etiketsiz X-ray görüntü seti ile desteklenen küçük bir etiketli X-ray görüntü seti üzerinde eğitilerek kemik kırıklarını tespit etmek için kullanılabilir. Ancak, yarı denetimli öğrenme genellikle veri dağılımı hakkında varsayımlara dayanmaktadır; bu varsayımlar ihlal edildiğinde model performansının düşmesine neden olabilir. Algoritmanın seçimi ve

etiketsiz verileri nasıl kullandığı, modelin kalitesini önemli ölçüde etkilemektedir. Modelin kendi yanlış tahminlerini daha fazla eğitimde kullanarak pekiştirmemesi için kalite kontrolü hayati önem taşımaktadır.

3.1.4 Takviyeli öğrenme

Takviyeli öğrenme (RL), bir ajanın belirli eylemleri gerçekleştirerek ve bu eylemlerden kaynaklanan ödülleri veya cezaları gözlemleyerek kararlar almayı öğrendiği bir makine öğrenimi tekniğidir. Doğru cevaplarla modelleri eğiten gözetimli öğrenmeden farklıdır. RL'de ana kavramlar arasında öğrenen veya karar verici olarak ajan, ajanın etkileşimde bulunduğu fiziksel dünya olarak çevre, mevcut durumu temsil eden durum, tüm olası hamleler olarak eylem, geri bildirim sinyali olarak ödül, mevcut duruma göre bir sonraki eylemi belirlemek için strateji olarak politika ve gelecekteki ödüller için indirim ile beklenen uzun vadeli dönüşün tahmini olarak değer fonksiyonu yer almaktadır. RL, tıbbi görüntülemede, özellikle görüntü analizi ve navigasyonu, tedavi optimizasyonu ve etkileşimli segmentasyonda uygulanabilmektedir (Hu *et al.* 2022). Zorluklar arasında, istenmeyen davranışları önlemek için ödül fonksiyonunun dikkatli bir şekilde tasarlanması, etkili öğrenme için gereken büyük örnek sayısı nedeniyle örnek verimsizliği ve keşif ile sömürü arasında denge kurulması yer almaktadır. RL, ardışık karar verme problemleri için güçlü bir çerçeve sunsa da, tıbbi görüntülemedeki uygulaması hala erken aşamalarında olup, sıklıkla daha teorik veya klinik pratiğe göre kontrol edilen araştırma ortamlarında uygulanmaktadır. Uygun ödüllerin tanımlanması ve tıbbi ortamın dinamik doğasının karmaşıklığı, halen araştırılmakta olan benzersiz zorluklar sunmaktadır. Bununla birlikte, RL'nin kişiselleştirilmiş tıp ve uyarlanabilir müdahalelere katkıda bulunma potansiyeli önemli olup, aktif bir araştırma alanıdır (Buffer *et al.* 2007).

3.2 Derin Öğrenme

DL, insan beyninin sinir ağlarından esinlenerek nöral ağları kullanan bir makine öğrenimi tekniğidir. Bu ağlar, verileri işleyen çok katmanlı birbirine bağlı düğümler veya nöronlardan oluşmaktadır. Bu derinlik, DL modellerinin verilerin karmaşık, hiyerarşik temsillerini öğrenmesine olanak tanır, bu da onları görüntüler, ses ve metin gibi

yapılandırılmamış verileri içeren görevler için özellikle etkili kılar (Polson and Sokolov 2019). DL'nin temel bileşenleri arasında nöral ağlar, giriş katmanları, gizli katmanlar ve çıkış katmanları yer almaktadır. Ağ içindeki ağırlıklar ve yanlılıklar, hatayı en aza indirmek için eğitim sırasında ayarlanmaktadır. Aktivasyon fonksiyonu, modelin doğrusal olmayan ilişkileri öğrenmesine yardımcı olurken, kayıp fonksiyonu modelin gerçek sonuçları tahmin etmedeki doğruluğunu ölçmektedir. Optimizasyon, kayıp fonksiyonunu en aza indirmek için ağırlıkları ve yanlılıkları ayarlamaktadır. Eğitim süreci, ağa büyük miktarda veri beslemeyi ve model hatalarına yanıt olarak ağırlıkları ve yanlılıkları ayarlamak için bir algoritma kullanmayı içermektedir. Bu süreç, hata gradyanını her ağırlığa göre hesaplayan ve hatayı en çok azaltacak şekilde her ağırlığı ayarlayan geri yayılım olarak bilinmektedir (Mathew *et al.* 2020).


CNN'ler, görüntüler gibi kafes benzeri verileri işlemek için kullanılırken, tekrarlayan sinir ağları zaman serileri veya dil gibi ardışık verileri işlemek için kullanılmaktadır. Otokodlayıcılar, özellik öğrenme ve boyut indirgeme gibi gözetimsiz görevler için kullanılmaktadır. Üretken karşıt ağlar, iki sinir ağından oluşmakta ve bu ağlar, bir üretici ve bir ayırt edici olarak eş zamanlı olarak eğitilmektedir (Bahmei *et al.* 2022, Zhu *et al.* 2018, Dai *et al.* 2016) (Şekil 3.4). Bu ağlar, girdi verilerine benzer yeni veriler üretmek için kullanılmaktadır.



Şekil 3.4 Derin öğrenme türü

3.2.1 Evrişimsel sinir ağıları

CNN'ler, bilgisayar görüşü ve görüntü sınıflandırma, segmentasyon ve nesne tespiti gibi alanlarda uygulamalara sahip olan görsel imajları analiz etmek için kullanılan derin sinir ağılarıdır. CNN'ler, Evrişim Katmanı, ReLU Katmanı, Havuzlama Katmanı, Tam Bağlı Katman, Dropout ve Softmax Fonksiyonu dahil olmak üzere birkaç temel kavramdan oluşmaktadır (Rahman *et al.* 2020). Eğitim sırasında, CNN'ler evrişimli, ReLU ve havuzlama katmanlarını gerçekleştirmek için büyük bir etiketli görüntü seti kullanır ve ardından tam bağlı katmanları uygular. Kayıp fonksiyonu, tahminlerdeki hatayı hesaplar, geri yayılım ise kaybın ağırlıklara göre gradyanlarını hesaplar. Genellikle stokastik gradyan inişi olan bir optimizasyon algoritması, kaybı en aza indirmek için ağırlıkları ayarlar. CNN'lerin tıbbi görüntüleme uygulamaları arasında tanısal görüntüleme, görüntü segmentasyonu, görüntü iyileştirme ve gerçek zamanlı analiz bulunmaktadır (Purwono *et al.* 2023) (Şekil 3.5).




Şekil 3.5 Mimari CNN tabanlı kemik fraksiyonları (Rahman *et al.* 2020)

Ancak, zorluklar arasında veri erişilebilirliği, yorumlanabilirlik ve genelleştirme bulunmaktadır. Etkili eğitim için büyük veri kümeleri gerekmektedir, bu da gizlilik endişeleri ve etiketleme uzmanlığı nedeniyle zorlayıcı olabilmektedir. CNN'lerin "kara kutu" doğası, kararların arkasındaki nedenin anlaşılmasının hayati olduğu sağlık hizmetlerinde önemli bir sorun olabilmektedir. CNN'ler için gelecek yönler, mimarilerde ve eğitim tekniklerinde ilerlemeleri içermekte olup, bu ilerlemeler arasında büyük etiketli veri kümelerinin kıtlığı nedeniyle bir görevden diğerine modelleri uyarlayan transfer öğrenme bulunmaktadır. Ayrıca, özellik haritalarının görselleştirilmesi ve dikkat

mekanizmaları gibi yorumlanabilirliği artırma çabaları, klinik uygulamada kabul edilmeleri ve güvenilirlikleri için kritik öneme sahiptir (Rahman *et al.* 2020).

3.2.2 Tekrarlayan sinir ağıları

RNN'ler, doğal dil işleme için metin, borsa tahmini için zaman serileri veya biyoenformatikteki sıra verileri gibi veri dizilerindeki örüntüleri tanımak üzere tasarlanmış yapay sinir ağlarıdır (Marhon *et al.* 2013). RNN'ler, zaman içindeki diziler arasında bağlantılar oluşturabilme yetenekleriyle diğer sinir ağlarından kendilerini ayırmaktadır, bu da onların girdi dizilerini işleyebilmelerini sağlamaktadır. RNN'lerin temel kavramları arasında bir döngü mekanizması, gizli durum, zaman adımları ve zaman içinde geri yayılım (BPTT) bulunmaktadır (Şekil 3.6) (Khuong 2020).




Şekil 3.6 RNN'nin temel mimarisi (Khuong 2020)

RNN'lerin çeşitli türleri bulunmaktadır; bunlar arasında Vanilya RNN'ler, Uzun Kısa Süreli Bellek Ağları (LSTM'ler) ve Kapılı tekrarlayan birimler yer almaktadır. Ancak, RNN'ler kaybolan gradyan sorunları, üssel büyüme ve hesaplama yoğunluğu gibi zorluklarla karşı karşıya kalmaktadır. Vanilya RNN'ler en basit formdayken, LSTM'ler daha verimli olup uzun diziler boyunca bilgiyi daha iyi koruyabilmektedir. Kapılı tekrarlayan birimler, bilgi akışını kontrol etmek için kapı mekanizmaları kullanmaktadır. RNN'ler, ardışık doğaları nedeniyle zaman adımları arasında paralelleştirme yapılmasını zorlaştıran ve uzun vadeli bağımlılıkları öğrenmede zorluklarla karşılaşmaktadır (Ming *et al.* 2017). Tıbbi görüntüleme, RNN'ler zaman serisi veri analizi, tıbbi görüntü açıklama oluşturma ve hasta yolculuğu modelleme gibi uygulamalara sahiptir. Bu

uygulamalar, tıbbi izleme cihazlarındaki zaman serisi verilerini analiz etmeyi, tıbbi görüntüler için otomatik açıklamalar üretmeyi ve sonuçları veya gelecekteki olayları tahmin etmek için hasta yolculuklarını modellemeyi içermektedir.

3.2.3 Üretken rekabet ağıları


Üretken Karşıt Ağlar (GAN'lar), denetimsiz makine öğreniminde kullanılan yapay zeka algoritmalarıdır ve giriş verilerine benzeyen yeni veriler üretmeyi amaçlar. Ian Goodfellow ve meslektaşları tarafından 2014 yılında tanıtılmış olup, özellikle kemik kırıkları ve tıbbi görüntüleme bağlamında oldukça faydalı olabilirler. GAN'lar aynı zamanda verileri anonimleştirebilir, kritik tıbbi bilgileri korurken tanımlanabilir bilgileri kaldırarak veya değiştirerek. Bu süreç, hasta mahremiyetinden ödün vermeden kamu yayını veya araştırma amaçları için güvenli veri kümelerinin sağlanmasını garanti eder. GAN'lar, görüntü kalitesini artırabilir, çözünürlüğü yükselterek, gürültüyü azaltarak veya görüntülerin eksik kısımlarını yeniden oluşturarak daha iyi tanı ve tedavilere yol açabilir. Sentetik lezyon üretimi, GAN'ların başka bir potansiyel uygulamasıdır. GAN'lar, tıbbi profesyonellere geniş bir vaka çalışması çeşitliliği sağlayan sentetik lezyonlar veya kırıklar içeren görüntüler üretebilir. Çapraz modallik görüntü çevirisi, GAN'ların başka bir potansiyel kullanımıdır (Saxena and Cao 2021). GAN'lar doğrudan kemik kırıklarını teşhis etmese de, tıbbi görüntüleri üretme ve geliştirme yetenekleri, veri kümelerini genişletmek, eğitimi iyileştirmek ve dolaylı olarak tanı süreçlerini geliştirmek için değerli bir araç sunar (Şekil 3.7).



Şekil 3.7 GAN temelli kemik fraksiyonları

3.2.4 Otokodlayıcı

Otoenkoderler, etiketsiz verilerin boyut azaltma veya özellik öğrenimi için verimli temsillerini öğrenmek amacıyla kullanılan yapay sinir ağlarıdır. Bu ağlar, girişi daha düşük boyutlu bir kod haline sıkıştırır ve bunu doğru bir şekilde yeniden yapılandırmaktadır; bu süreçte kodlayıcı ve kod çözücü görev almaktadır. Otoenkoderlerin çeşitli türleri arasında vanilya, evrişimli, seyrek, gürültü giderici ve varyasyonel otoenkoderler yer almaktadır. Vanilya otoenkoderler tam bağlantılı ağlar olup, evrişimli otoenkoderler görüntü verileri için evrişim katmanlarını kullanmaktadır. Seyrek otoenkoderler, daha sağlam özellikler öğrenmek için gizli katmanlarda bir seyreklik kısıtlaması içermektedir. Gürültü giderici otoenkoderler, modelin daha temel özellikleri öğrenmesine yardımcı olmak amacıyla bozulmuş versiyonlardan orijinal girişi yeniden yapılandırmak üzere eğitilmektedir. Varyasyonel otoenkoderler, giriş dağılımını modelleyip yeni veri noktaları üretmekte ve kodlama ile kod çözme sürecine olasılıksal bir büküm eklemektedir (Stewart 2020) (Şekil 3.8).



Şekil 3.8 Otoenkoderler (Stewart 2020)

Otoenkoderler, kemik kırıklarının ve tıbbi görüntülemenin analizini desteklemek için çeşitli şekillerde uygulanabilir. X-ray veya diğer tıbbi görüntülerdeki ilgili özellikleri tanımayı öğrenebilir, tıbbi görüntülerin gürültüsünü azaltarak netliği artırabilir, tıbbi görüntüleri daha düşük boyutlu bir uzaya sıkıştırabilir ve öğrenilen sağlıklı modellerden sapmalar olarak anomalileri veya kırıkları tespit edebilir. Otoenkoderlerin gizli uzayı, veri setini genişleterek dolaylı olarak kemik kırıklarının tespitine destek olacak şekilde veri artırma için de araştırılabilir. Ancak, otoenkoderlerin çeşitli zorlukları bulunmaktadır, bunlar arasında yeniden yapılandırma kaybı, aşırı uyum ve yorumlanabilirlik yer almaktadır. Kayıp fonksiyonunun seçimi, özellikle tıbbi taramalar gibi karmaşık görüntüler için yeniden yapılandırma kalitesini önemli ölçüde etkileyebilir. Otoenkoderler, ön işlemeden ve özellik çıkarmadan anomali tespitine kadar olan yetenekleriyle tıbbi görüntülemeye güçlü bir araçtır (Cheng *et al.* 2021).

3.3 Görüntü İşleme

Görüntü işleme, dijital görüntüleri geliştirmeye, analiz etmeye ve işlemeye yönelik geniş bir teknik yelpazesi olan bir alandır. Bilgisayar görüşü alanında temel bir bölge olup, tıbbi teşhisten otonom sürüş sistemlerine kadar uzanan uygulamalar için kritik öneme sahiptir (Suguna *et al.* 2023). Görüntü işlemenin açıklanabileceği başlıklar şu şekildedir:

1. Görüntü İşlemenin Temelleri

Görüntü işleme, görüntüleri dijital formlara dönüştürmeyi ve üzerlerinde kullanışlı bilgileri çıkarmak veya kalitelerini artırmak için işlemler yapmayı içermektedir. Görüntü işlemedeki temel adımlar tipik olarak şunları içermektedir:

- Görüntünün İçerik Aktarılması: Bu, bir optik tarayıcı ile veya doğrudan bir dijital kamera aracılığıyla yapılmaktadır.
- Görüntünün Analiz Edilmesi ve İşlenmesi: Gereksinimlere göre görüntü analiz edilmekte veya değiştirilmektedir.

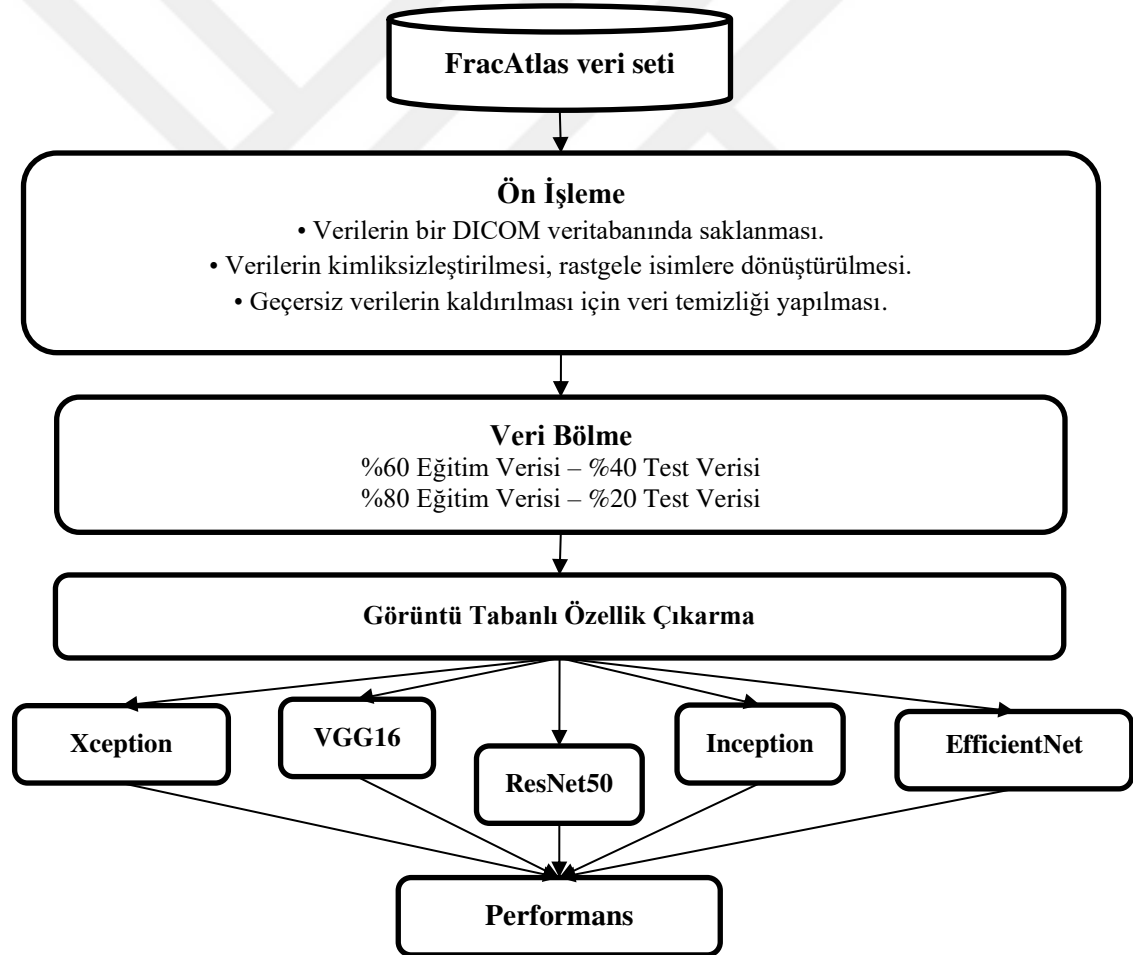
- Sonuçların Çıktısı: Sonuç, değiştirilmiş bir görüntü veya görüntü analizine dayalı bir rapor olabilmektedir.

2. Görüntü İşleme Teknikleri

- Görüntü Geliştirme: Görüntünün görsel görünümünü iyileştirmeyi veya görüntüleri analiz için daha uygun bir forma dönüştürmeyi amaçlamaktadır. Teknikler arasında kontrast germe, histogram eşitleme ve gürültü azaltma yer almaktadır.
- Görüntü Restorasyonu: Daha karmaşık bir görüntü işleme formu olup, bozulmuş bir görüntüyü, bozulma fenomeninin önceden bilinen bilgileri kullanarak yeniden yapılandırmayı veya kurtarmayı denemektedir. Yaygın uygulamalar arasında bulanıklıkların, gürültünün ve kamera odak dışılığının giderilmesi yer almaktadır.
- Renkli Görüntü İşleme: Renkli görüntülerin manipülasyonu ile ilgilenmekte ve renk eşleme, renk dengesi ve renk normalizasyonu gibi işlemleri içermektedir.
- Morfolojik İşleme: Şeklin temsil edilmesi ve tanımlanmasında kullanışlı görüntü bileşenlerinin çıkarılmasını içermekte ve genleşme, erozyon, açılma ve kapanma gibi teknikleri kullanmaktadır.
- Görüntü Segmentasyonu: Dijital bir görüntüyü daha yönetilebilir hale getirmek ve nesneleri ile sınırları daha net bir şekilde tanımlamak için çoklu segmentlere ayırma işlemidir. Teknikler arasında eşikleme, kümeleme ve kenar tabanlı segmentasyon yer almaktadır.

4. MATERYAL VE YÖNTEM

Önerilen metodoloji, X-ray görüntülerini kullanarak kemik kırıklarını tespit etmek için DL tabanlı bir sistem geliştirmeyi içermekte ve birkaç temel adımı kapsamaktadır. Bunlar arasında veri toplama, ön işleme, model seçimi ve eğitimi ile performans değerlendirmesi bulunmaktadır. Veri toplama aşaması, kırılmış ve kırılmamış kemiklerin görüntülerini içeren çeşitli tıbbi görüntü veritabanlarından geniş bir X-ray görüntüsü veri seti toplamayı içermektedir. Model seçimi ve eğitimi, farklı DL modelleri ile deney yapmayı içermektedir. Model değerlendirme, doğruluk, kesinlik, duyarlılık, F1 puanı gibi performans metriklerini içermektedir. Şekil 4.1, önerilen çalışmanın akış şemasını göstermektedir.




Şekil 4.1 Önerilen çalışmanın akış diyagramı

Akış şeması, DL modeli eğitimi için kemik kırığı veri setini işleme sürecini anlatmaktadır. Veri seti, kemik kırıklarının X-ray görüntüleri gibi tıbbi görüntülerden oluşmaktadır. Veri seti, DICOM veritabanında veri depolama, verileri anonimleştirme, rastgele isimlere dönüştürme ve geçersiz verileri kaldırma işlemleri ile ön işlemden geçmektedir. Veri seti %60 ve %40 olarak bölünmekte, bunun %80'i eğitim ve %20'si test için kullanılmaktadır. Özellik çıkarma işlemi, görüntülerden ilgili özellikleri çıkarmak için önceden eğitilmiş ağlar kullanılarak gerçekleştirilmektedir. Özellik çıkarma sonrasında, modelin performansı ölçülmektedir. Özellik çıkarma ve sınıflandırma görevleri için bilinen bazı DL mimarileri arasında Xception, VGG16, ResNet50, Inception ve EfficientNetV2 bulunmaktadır. Her mimari benzersiz özelliklere sahiptir ve doğruluk, verimlilik veya hız gibi farklı amaçlar göz önünde bulundurularak tasarlanmıştır. Kemik kırığı tespiti bağlamında, mimarinin seçimi, uygulama ihtiyaçlarını en iyi karşılayacak bu faktörler arasındaki dengeye dayanmalıdır. Kemik kırığı veri setini ele alma bu kapsamlı yaklaşımı, görüntülerin hazırlanmasını, işlenmesini, modelin eğitilmesini ve test edilmesini ve çeşitli ileri nöral ağ mimarileri ile performansının değerlendirilmesini içermektedir. Uygun mimari seçilerek, model hastanın özel ihtiyaçlarını etkili bir şekilde ele alabilmektedir.

4.1 Veri Seti

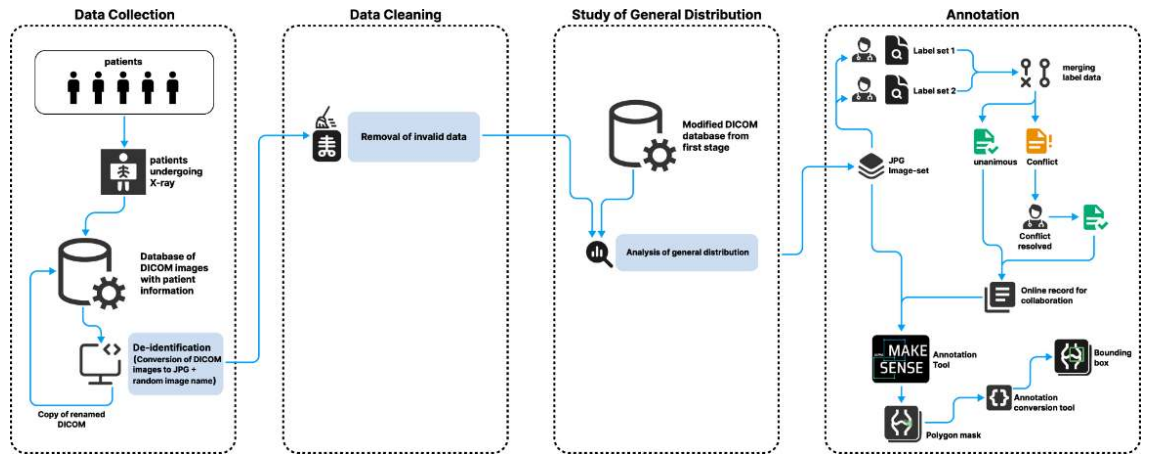
Dijital radyografi, kırık kemikleri tespit etmek için yaygın ve uygun maliyetli bir yöntemdir ve eğitimli bir profesyonel tarafından kullanılması gerekmektedir. Bilgisayar vizyonu tekniklerinin sayısının fazla olması nedeniyle, bilgisayar destekli analiz kullanımı hızla artmaktadır. Ancak, mevcut X-ray örneklerinin ya çok az olması ya da yeterli açıklamalara sahip olmaması, makine öğrenmesindeki ilerlemeyi engellemektedir. FracAtlas, üç hastaneden toplanmış 4,083 adet X-ray görüntüsü içermektedir. Bu görüntülerin kapsamlı bir incelemesinden sonra, kırıklar tanımlanmış, kategorize edilmiş ve açıklanmıştır. Koleksiyondaki 717 görüntü, bir maske ve bir sınırlayıcı kutu ile birlikte gelmektedir. Koleksiyon, toplam 922 kırık içermekte olup, kemik kırıklarını tespit etmek için ML yöntemleri geliştiren araştırmacılar için değerli bir kaynak oluşturmaktadır (Şekil 4.2).



Şekil 4.2 Örnek veri seti

4.2 Ön İşleme

FracAtlas veri seti (Abedeen ve diğerleri, 2023), genel bir amaçla DICOM formatında X-ray görüntüleri toplanarak oluşturulmuştur ve daha sonra anonimleştirme amaçları için JPG formatına dönüştürülmüştür. Veri seti, insan parçalarının görüntülerini içermeyecek şekilde filtrelenmiştir ve hastanelerdeki aşama 2 görüntülerinin dağılımı analiz edilmiştir. Bir ortopedi uzmanı fotoğrafları incelemiş ve uzman radyologlar tarafından açıklama yapılmıştır. Maskeler, açık kaynaklı yazılım kullanılarak manuel olarak üretilmiş ve daha sonra makine öğrenimi uygulamalarında kullanılmalarını kolaylaştırmak amacıyla diğer açıklama formatlarına dönüştürülmüştür. Ön işleme, Şekil 4.3'te gösterilmektedir.




Şekil 4.3 Veri setinin hazırlanması (Abedeen *et al.* 2023)

4.3 Önerilen Modeller

Tıbbi görüntüleme verilerinin toplanması ve hazırlanması süreci birkaç adımdan oluşmaktadır. İlk adım, X-ray işlemlerinden geçen hastalardan veri toplamayı içermekte, bu veriler daha sonra DICOM görüntüleri ve hasta bilgileri içeren bir veritabanında saklanmaktadır. Ardından veriler anonimleştirilir, kişisel tanımlayıcılar kaldırılır ve rastgele isimlerle DICOM formatına dönüştürülür. Daha sonra veri temizleme işlemi gerçekleştirilir, geçersiz veriler kaldırılarak analiz için yüksek kaliteli verilerin sağlanması amaçlanır. Temizlenmiş DICOM veritabanı, verilerin dağılımını anlamak amacıyla başlangıç analizlerinden geçer, örneğin görüntülerdeki durumların çeşitliliği veya hasta popülasyonunun demografik özellikleri gibi. Son aşama, verilerin doğruluğunu sağlamak amacıyla en az iki bağımsız etiketle etiketlenmesini içeren açıklama sürecidir.

4.3.1 Xception

Bu DL modeli, Xception olarak bilinir ve François Chollet tarafından 2017 yılında görüntüleri sınıflandırmak için yaratılmıştır (Chollet 2017). Xception, az parametre ve yüksek hızda verimli bir şekilde görüntü sınıflandırma yeteneğiyle tanınan Inception mimarisini temel almaktadır. Xception, derinlik tabanlı ayrılabilir konvolüsyonlar kullanmaktadır; bu teknik, girdinin her kanalını bağımsız olarak işler ve sonuçları yeni bir kanal alanına yansıtır. Bu yaklaşım, parametre sayısını ve hesaplama yükünü azaltarak modelin verimliliğini artırırken performansından ödün vermez. Xception, parametre kullanımını optimize eder ve daha az hesaplama gücü gerektirirken Inception modelleri kadar iyi veya daha iyi performans sergileyebilir. Özellikle sınırlı hesaplama kaynaklarına sahip senaryolarda oldukça faydalıdır (Şekil 4.4).




Şekil 4.4 Xception akış şeması diyagramı (Chollet 2017)

Xception yapısı, geniş bir veri seti ve problem türleri yelpazesine iyi uyum sağlayacak şekilde tasarlanmıştır ve bu özelliği ile makine öğrenimi uygulayıcıları için değerli bir araç haline gelmiştir. Global ortalama havuzlama kullanımı, modelin karmaşıklığını azaltır ve aşırı uyumu önlemeye yardımcı olur. Xception, transfer öğrenme, görüntü sınıflandırma ve nesne tanıma gibi uygulamaları destekleyen çok yönlü bir modeldir. Etkinliği ve uyum kabiliyeti nedeniyle, özellikle daha küçük veri setlerinde önceden eğitilmiş modellerin ince ayar yapılması veya başlangıç eğitiminin ötesinde belirli görüntü tanıma görevleri için sıklıkla tercih edilmektedir. Xception'ın tanıtılması, derinlik tabanlı ayrılabilir konvolüsyonların kullanımının, son derece verimli görüntü tanıma modelleri oluşturmadaki etkinliğini göstererek, konvolüsyonel sinir ağlarının tasarımında önemli bir ilerleme olarak kabul edilmektedir.

4.3.2 VGG16

VGG16, 2014 yılında Oxford Üniversitesi'nden Simonyan ve Zisserman tarafından yaratılan bir konvolüsyonel sinir ağı modelidir. VGG16'nın doğruluğu, görüntü sınıflandırma ve görsel tanıma görevleri için bir referans noktası olan ImageNet veri seti

kullanılarak gösterilmektedir. VGG16, sonunda 3 tam bağlantılı katman bulunan 13 konvolüsyonel katmandan oluşan düzenli bir mimariye sahiptir. Her konvolüsyonel katmandan sonra ReLU aktivasyon fonksiyonu uygulanır; bu, ağa doğrusal olmayan özellikler katarak daha karmaşık desenleri öğrenmesini sağlar. VGG16, yalnızca 224x224 RGB görüntülerini kabul eder ve bu görüntüler ağa girilmeden önce ön işleminden geçirilmelidir. Yaklaşık 138 milyon parametre ile, eğitim ve çıkarım için en fazla bellek ve hesaplama gücü gerektiren modellerden biridir. VGG16, görüntü sınıflandırma, transfer öğrenme ve özellik çıkarma konularında üstün performans sergiler. Binlerce kategoriye görüntüleri doğru bir şekilde sınıflandırmada olağanüstü başarılıdır. Sıkça transfer öğrenme için önceden eğitilmiş model olarak kullanılan VGG16, daha az veri ile yeni görevlere öğrenilmiş ağırlıkları uygular. VGG16'nın tasarım ilkeleri, diğer sinir ağ mimarilerine ilham vermiş ve bilgisayarla görme alanında DL için temel bir model haline gelmiştir (Boesch 2021) (Şekil 4.5).




Şekil 4.5 VGG16 mimarisi (Boesch 2021)

4.3.3 ResNet50

ResNet50, özellikle görüntü tanıma ve sınıflandırma görevleri için tasarlanmış 50 katmanlı bir DL modelidir. Ağdaki belirli katmanları atlayarak kaybolan gradyan sorununu ele almaktadır ve bu sayede, eğitim performansından ödün vermeden önceki

mimarilere göre çok daha derin olabilmektedir. ResNet50'nin derin ağ yapısı, girdi görüntülerinden karmaşık özellik hiyerarşilerini öğrenmesini sağlamakta ve böylece görüntü sınıflandırma görevleri için oldukça etkili hale getirmektedir (Kundu 2023). Model, görüntü verilerini işlemek ve öğrenmek için konvolüsyonel katmanlar kullanmakta, sınıflandırma için gerekli olan desenleri, şekilleri ve özellikleri tanımlamaya yardımcı olmaktadır. Ayrıca, modeldeki toplam parametre sayısını azaltarak aşırı uyum riskini azaltan küresel ortalama havuzlama katmanını kullanmaktadır. ResNet50, görüntü sınıflandırmasının ötesinde, nesne tespiti, görüntü segmentasyonu ve bilgisayarla görme alanında daha karmaşık modeller için bir temel olarak çeşitli uygulamalarda yaygın olarak benimsenmiştir. Transfer öğrenme, öğrenilmiş özelliklerden yararlanılmasını sağlayarak, küçük veri setlerinin bile modelin özelliklerinden faydalanmasına ve geniş bir görev yelpazesinde performansın önemli ölçüde iyileştirilmesine imkan tanımaktadır. ResNet50, X-ray görüntülerinde kemik kırıklarının otomatik tespiti için kullanılabilir ve bu, tıbbi görüntüleme alanında DL yöntemlerinin önemli bir uygulamasını temsil etmektedir.


ResNet50'nin X-ray görüntülerinde kemik kırıklarının otomatik tespiti için kullanılması, DL'nin tıbbi teşhisleri dönüştürme potansiyelini sergilemektedir. ResNet50'nin gelişmiş özellikleri ile tıbbi görüntülemenin kritik ihtiyaçlarının kombinasyonu, teşhis doğruluğunu artırabilir, tedavi sürelerini hızlandırabilir ve sonuç olarak daha iyi hasta sonuçlarına yol açabilir. Ancak, klinik ortamlarda başarılı bir uygulama, veri işleme, model eğitimi ve tıbbi standartlara karşı doğrulama gibi konularda dikkatli bir değerlendirme gerektirmektedir (Şekil 4.6).



Şekil 4.6 ResNet50 mimarisi (Kundu 2023)

4.3.4 InceptionV3

InceptionV3 veya GoogLeNet, Google tarafından geliştirilen ve görüntü tanıma görevlerinde yüksek doğruluk oranıyla tanınan bir CNN mimarisidir (Google 2018). Benzersiz mimarisi, yönetilebilir bir hesaplama yükü ile yüksek doğruluk sağlamasına imkan tanır. InceptionV3'ün temel özellikleri arasında, parametre ve hesaplama ihtiyacını azaltan faktörize konvolüsyonlar, inception modüllerinde filtre bankası çıktılarını genişletme, eğitim sırasında alt katmanlarda ek gradyan enjekte etmek için yardımcı sınıflandırıcılar kullanma, artırılmış adım sayısı ile konvolüsyonlar kullanarak etkili ızgara boyutu azaltma ve birçok katmanında toplu normalleştirme bulunmaktadır (Şekil 4.7).



Şekil 4.7 Inception V3 mimarisi (Google 2018)


InceptionV3'ün uygulamaları arasında görüntü sınıflandırma, nesne tespiti, görüntü segmentasyonu ve transfer öğrenme bulunmaktadır. Binlerce kategoriye görüntüleri sınıflandırmada üstün bir başarı gösterir ve sıklıkla görüntü sınıflandırma yarışmalarında bir referans noktası olarak kullanılır. Ayrıca, daha spesifik görüntü tanıma görevleri için nesne tespiti, görüntü segmentasyonu ve transfer öğrenmede de kullanılabilir. InceptionV3'ün avantajları arasında yüksek doğruluk, hesaplama verimliliği ve çok yönlülük yer alır. Mimarisi, etkinliği tehlikeye atmadan hesaplama talebini azaltır, bu da hem yüksek uç hem de orta düzeyde güçlü donanımlar için uygun olmasını sağlar. Modelin yapısı, temel görüntü sınıflandırmanın ötesinde geniş bir uygulama yelpazesine

uyum sađlanmasını ve ince ayar yapılmasını mümkün kılar. InceptionV3, bilgisayarla görme için DLde önemli bir ilerleme temsil eder ve performansı ve verimliliđi artırmak için yenilikçi mimari fikirleri bir araya getirir. Göreceli olarak daha düşük hesaplama maliyetleriyle karmaşık görüntü tanıma görevlerini ele alabilme yeteneđi, onu makine öğrenimi uygulayıcılarının araç kutusunda vazgeçilmez bir unsur haline getirmiştir.

4.3.5 EfficientNet

EfficientNet, 2019 yılında Google araştırmacıları tarafından geliştirilen bir CNN modelleri ailesidir. Bu modeller, CNN'leri yapılandırılmış bir şekilde ölçeklendirerek üstün verimlilik ve doğruluk elde etmeyi amaçlamaktadır. Bileşik ölçeklendirme yöntemi tanıtılmıştır, bu yöntem ađ genişliğini, derinliğini ve çözünürlüğünü sabit ölçeklendirme katsayıları ile düzgün bir şekilde ölçeklendirir. Bu yaklaşım, ađ boyutlarının dengesinin model performansı ve verimliliđi üzerinde önemli bir etkiye sahip olduđu fikrine dayanmaktadır (Mingxing 2019).

EfficientNet, doğruluk ve verimlilik için optimize edilmiş bir temel ađ olan EfficientNet-B0 üzerine uygulanmaktadır. Ađ, çeşitli doğruluk ve verimlilik arasındaki denge sunan bir model ailesi elde etmek üzere ölçeklendirilmektedir (EfficientNet-B1'den B7'ye kadar). Her bir sonraki model, daha fazla parametreye sahip olup daha fazla hesaplama gerektirmekte, ancak genellikle görüntü tanıma görevlerinde daha yüksek doğruluk sağlamaktadır. EfficientNet, MobileNetV2 ve MnasNet'te kullanılanlara benzer, mobil görüş görevleri için verimli ve etkili olan lineer darboğazlara sahip ters residual bloklar (MBConv) kullanmaktadır. Ayrıca, kanallar arasındaki bağımlılıkları açıkça modelleyerek kanal bazında özellik tepkilerini adaptif olarak yeniden kalibre eden sıkıştırma ve uyarılma optimizasyonunu kullanmaktadır. EfficientNet'in uygulamaları arasında görüntü sınıflandırma, nesne tespiti ve segmentasyon, transfer öğrenme bulunmaktadır. Devlet-sanatı verimliliđi ve doğruluđu, ölçeklenebilirliđi ve çok yönlülüđu ile çeşitli gerçek dünya uygulamaları için uygun hale gelmektedir (Şekil 4.8).



Şekil 4.8 EfficientNet mimarisi (Mingxing 2019)

EfficientNet, konvolüsyonel ağların tasarımı ve ölçeklendirilmesinde önemli bir ilerleme temsil etmekte olup, çeşitli gerçek dünya uygulamaları için faydalı olan yüksek verimlilik ve doğruluk karışımını sunmaktadır.

4.4 Modellerin Performansının Değerlendirilmesi

DL bağlamında, özellikle tıbbi görüntülerden kemik kırıklarının otomatik tespiti gibi uygulamalarda, bir modelin performansını değerlendirmek, etkinliğini ve klinik ortamlarda kullanıma uygunluğunu anlamak için hayati öneme sahiptir. Bu amaçla genellikle çeşitli metrikler kullanılmaktadır; her biri modelin performansına dair farklı içgörüler sağlamaktadır.

4.4.1 Doğruluk

Doğruluk, en sezgisel metriklerden biridir. Model tarafından yapılan tüm tahminler arasında doğru tahminlerin (hem gerçek pozitifler hem de gerçek negatifler) oranını ölçer. Denklem (4.1)'de belirtildiği gibi hesaplanmaktadır:

$$\text{Doğruluk} = \frac{\text{Number Doğru Tahminlerin Sayısı}}{\text{Toplam Tahmin Sayısı}} \quad (4.1)$$

4.4.2 Hassasiyet

Hassasiyet (veya Pozitif Tahmin Değeri), pozitif sınıfta gerçek pozitif tahminlerin oranını ölçer. Modelin negatif bir örnek etiketlemesini önleme yeteneğine odaklanmaktadır. Bu, yanlışlıkla sağlıklı bir hastayı kırık olarak tanımlamanın gereksiz tedavilere yol açabileceği tıbbi teşhislerde özellikle önemlidir. Hassasiyet, Denklem (4.2)'de tanımlandığı gibi tanımlanmaktadır:

$$\text{Hassasiyet} = \frac{\text{Gerçek Pozitifler}}{\text{Gerçek Pozitifler} + \text{Yanlış Pozitifler}} \quad (4.2)$$

Yüksek hassasiyet, düşük yanlış pozitif oranını gösterir, ancak yanlış negatifleri dikkate almaz

4.4.3 Duyarlılık

Duyarlılık, model tarafından doğru bir şekilde tespit edilen gerçek pozitiflerin oranını ölçer. Pozitif bir vakayı kaçırmak (örneğin, bir kırığı tespit edememek), hasta bakımı için ciddi sonuçlar doğurabileceği tıbbi bağlamlarda özellikle önemlidir. Hassasiyet, Denklem (4.3)'de tanımlandığı gibi hesaplanmaktadır:

$$\text{Duyarlılık} = \frac{\text{Gerçek Pozitifler}}{\text{Gerçek Pozitifler} + \text{Yanlış Negatifler}} \quad (4.3)$$

Yüksek hassasiyet, modelin pozitif vakaları tespit etmede etkili olduğunu gösterir ancak yanlış pozitiflerin sayısı hakkında bilgi vermez.

4.4.4 Hassasiyet ve duyarlılığın dengelenmesi

Genellikle hassasiyet ile duyarlılık arasında bir denge söz konusudur. Hassasiyeti artırmak genellikle duyarlılığın azalması pahasına gerçekleşir ve tersi de geçerlidir. Bu denge, Hassasiyet-duyarlılık Eğrisi kullanılarak görselleştirilebilir ve analiz edilebilir ve

bu metrikler arasındaki denge, Hassasiyet ve duyarlılığın harmonik ortalaması olan F1 Skoru ile nicel olarak değerlendirilebilir, Denklem (4.4):

$$F1 \text{ Skoru} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (4.4)$$

Hassasiyeti, duyarlılığı veya ikisini dengede tutmayı tercih etme seçimi, tıbbi uygulamanın özel gereksinimlerine bağlıdır. Örneğin, kırık tespitinde, gerçek bir kırığı kaçırmak (düşük duyarlılık) yanlışlıkla bir kırık tespit etmekten (düşük hassasiyet) daha zararlı kabul edilebilir, bu da klinik iş akışı ve hasta sonuçlarındaki yanlış pozitiflerin ve yanlış negatiflerin sonuçlarına bağlıdır.

5. BULGULAR VE TARTIŞMA


Bu bölümde, DL teknikleri kullanılarak X-ray görüntüleri üzerinde kemik kırıklarının otomatik tespiti için önerilen CNN modellerinin uygulanmasının sonuçları ele alınmaktadır.

5.1 Bilgisayar Sistem Konfigürasyonu

Bu çalışmada kullanılan bilgisayar cihazı, Core i5 işlemcili, 16.0 GB RAM ve 64-bit işletim sistemine sahip bir PC'dir. Windows 10 Pro sürümü yüklüdür.

5.2 Xception-FracAtlas Sonuçları

Karışıklık matrisi analizi, modelin 69 örneği doğru bir şekilde pozitif olarak, 94 örneği negatif olarak tanıdığını; 25 örneği negatif olmasına rağmen yanlışlıkla pozitif olarak, 61 örneği ise pozitif olmasına rağmen yanlışlıkla negatif olarak tahmin ettiğini göstermiştir. Model, eğitim verilerini artırarak her iki sınıf için tahminlerde de iyileşme göstermiştir; daha yüksek TP ve TN değerleri, her iki sınıf için iyileşmiş tahminleri göstermektedir. Daha düşük FP ve FN değerleri, modelin tahminlerde daha iyi hale geldiğini önermektedir (Şekil 5.1).



Şekil 5.1 Xception-FracAtlas'ın karışıklık matrisi

Çalışma, Xception-FracAtlas modelinin performansını %60 eğitim ve %40 test ile %80 eğitim ve %20 test oranlarında analiz etmiştir. Modelin doğruluğu, kırık olmayan durumlar üzerinden ölçülmüş, hassasiyeti 0.871 ve duyarlılık oranı 0.962 olarak belirlenmiştir. Modelin F1-skoru 0.914 olarak hesaplanmış, bu da hassasiyet ve duyarlılık arasında iyi bir denge olduğunu göstermektedir. Modelin doğruluğu %85 olarak belirlenmiş, bu da hem pozitif hem de negatif örnekleri doğru bir şekilde tahmin edebilme yeteneğini göstermektedir (Çizelge 5.1) ve (Çizelge 5.2).


Çizelge 5.1 %60-%40 Xception-FracAtlas sonuçları

DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırıksız	0.871	0.962	0.914	85%	5s 61ms
Kırık	0.709	0.393	0.506		


Çizelge 5.2 %80-%20 Xception-FracAtlas sonuçları

DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırıksız	0.882	0.873	0.826	85.53%	7s 57ms
Kırık	0.812	0.816	0.823		

Sonuçlar, kırıksız örneklerde kesinlikte küçük bir düşüş gösterdi; 0.871'den 0.852'ye düştü, ancak duyarlılıkta 0.962'den 0.873'e bir iyileşme oldu. Bu, modelin daha fazla gerçek pozitif yakaladığını ancak daha fazla yanlış pozitif yaptığını gösterebilir. Kırıksız örnekler için F1 skoru, kesinlik ile duyarlılık arasında bir denge kurulduğunu öneren 0.826'ya hafifçe düştü. Doğruluk oranı, %85.53 ile tutarlı kaldı ve bu, 60/40 bölünmesine göre küçük bir iyileşme olarak kabul edilebilir. Ayrıca, Şekil 5.2, Xception-FracAtlas için ROC'yi göstermektedir.



60%-40%




80%-20%

Şekil 5.2 Xception-FracAtlas için ROC

Xception modeli, 0.68 ve 0.70 AUC ile pozitif ve negatif sınıflar arasında makul bir ayırım yapabilmektedir. Ancak, özellikle değerler 1'e daha yakinken, iyileştirme alanı bulunmaktadır. Modelin ayırt edici yeteneği, 60/40'tan 80/20 eğitim/test bölünmesine geçildiğinde hafifçe artmaktadır.

5.3 VGG16-FracAtlas'ın Sonuçları

Derin CNN modeli VGG16-FracAtlas, iki farklı veri seti bölünmesinde (60%-40% ve 80%-20%) test edilmektedir. Şekil 5.3, yanlış pozitiflerde önemli bir azalma ve yanlış negatiflerde önemli bir artış göstermekteyken, ikinci bölünme yanlış pozitiflerde bir azalma ve yanlış negatiflerde bir artış göstermektedir.



Şekil 5.3 VGG16-FracAtlas için karışıklık matrisi

Performans metrikleri Çizelge 5.3'te sunulmuş olup, 'Kırksız' için 0.879 kesinlik ve 'Kırıklı' için 0.761 kesinlik, 'Kırksız' için 0.968 duyarlılık ve 'Kırıklı' için 0.432 duyarlılık, ve %86 doğruluk göstermiştir. Modelin bir tahmin yapma süresi 18.57 ms idi.

Çizelge 5.3 %60-%40 VGG16-FracAtlas sonuçları


DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırksız	0.879	0.968	0.921	86%	3s 77 ms
Kırık	0.761	0.432	0.551		

Çizelge 5.4, %80-%20 VGG16-FracAtlas sonuçlarını göstermektedir. Tablo 5.4'e göre, modelin 'Kırıklı' tespitinde kesinlik ve duyarlılık her ikisi de önemli ölçüde iyileşmiş, ancak 'Kırıksız' duyarlılığında bazı bozulmalar meydana gelmiştir. Artan doğruluk ve bölünmeler arası F1 skorlarındaki değişiklikler, modelin %80-%20 bölünmesinde daha büyük bir eğitim setinden faydalanabileceğini ve daha iyi genelleme yapabilmesine yardımcı olabileceğini öne sürmektedir, ancak bu daha uzun bir hesaplama süresiyle sonuçlanmaktadır.

Çizelge 5.4 %80-%20 VGG16-FracAtlas sonuçları

DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırıksız	0.879	0.928	0.901	87.61%	4s 98ms
Kırık	0.841	0.858	0.851		

Ayrıca, Şekil 5.4, VGG16 için ROC'yi iki bölünme modunda (60%-40% ve 80%-20%) göstermektedir.




Şekil 5.4 VGG16-FracAtlas için ROC

5.4 ResNet50-FracAtlas Sonuçları

Sağlanan karışıklık matrisleri, Şekil 5.5'te belirtilen iki farklı senaryo altında bir sınıflandırma modelinin performansını temsil etmektedir; eğitim bölünmeleri %60-%40 ve %80-%20 şeklindedir. Matris (a)'da model, negatif vakaları doğru bir şekilde tanıma konusunda oldukça iyi performans göstermekte, ancak pozitif vakalarla biraz mücadele etmektedir; bu durum, yüksek sayıda yanlış negatif ve ılımlı sayıda gerçek pozitif ile

gösterilmektedir. Matris (b)'de ise model, azalan yanlış pozitif sayısı ile belirtildiği gibi negatif vakaları tahmin etme konusunda daha ihtiyatlı veya doğru davranmaktadır. Ancak, gerçek pozitiflerdeki drastik azalma ve yanlış negatiflerdeki hafif artıştan anlaşılacağı üzere, pozitif vakaları tanıma konusunda önemli ölçüde daha kötüdür.



Şekil 5.5 ResNet50-fracatlas için karışıklık matrisi

Matris (a)'daki model, matris (b)'deki modele kıyasla daha yüksek duyarlılığa (pozitif vakaları tespit etme yeteneği) sahiptir ve bu, negatif vakaları tespit etme yeteneği olan özgüllüğü önceliklendirmekte gibi görünmektedir. %80-%20 bölünmesi (b), eğitim setinde pozitif sınıfın daha az örneğine yol açmış olabilir ki bu da pozitif tahminlerdeki zayıf performansı açıklayabilir. %60-%40 bölünmesi (a) ise daha dengeli bir eğitim seti sağlamış olup, özellikle pozitif tahminler için daha iyi bir genelleme sağlama potansiyeline sahiptir.

Çizelge 5.5, "Kırıklı" veya "Kırıksız" tespitine odaklanan bir sınıflandırma modelinin performansını değerlendiren metrikleri sunmaktadır. Modelin kırıklı için kesinliği 0.892 olarak belirtilmekte, bu da modelin negatif sınıfı kırıksız yaklaşık %89.2 oranında doğru tahmin ettiğini göstermektedir. Ancak, kırıklıyı yalnızca %43.4 oranında doğru tahmin edebilmekte, bu da bu sınıf için yüksek sayıda yanlış pozitif olduğunu öne sürmektedir. Modelin kırıksız için duyarlılığı 0.825, tüm gerçek hata olmayan vakaların %82.5'ini tespit edebilmekte ve kırıklı için %57.4, bu da iyileştirme alanı olduğunu göstermektedir. Kırıksız tahminler için F1 skoru nispeten yüksek olup, bu sınıf için etkili bir performansı

önermektedir. Modelin doğruluk oranı %77.7'dir, ancak sınıflar dengesiz olduğunda sınıfa özgü performansın tam bir resmini sağlamamaktadır.

Çizelge 5.5 %60-%40 ResNet50-FracAtlas sonuçları

DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırıksız	0.892	0.825	0.857	77.7%	5s 02 ms
Kırıkk	0.434	0.574	0.494		


"Kırıkk" durumu için kesinlik, 0.434 olarak oldukça düşüktür, bu da modelin kırıklı görüntülerini yalnızca %43.4 oranında doğru tahmin ettiğini göstermektedir. Duyarlılık ise 0.574'tir, bu da modelin tüm gerçek kırıklı vakaların %57.4'ünü tespit ettiğini göstermektedir. Kırıkk görüntüler için F1 skoru 0.494 olup, orta düzeyde bir performansı yansıtmaktadır. Bu durum için listelenmiş bir doğruluk veya süre bulunmamaktadır, bu da bu ölçülerin hesaplanmadığını veya yalnızca "Kırıkk" kategorisi için uygulanmadığını ima edebilir.

Çizelge 5.6, %80-%20 veri bölünmesi kullanılarak eğitilen ResNet50 mimarisine dayanan bir sınıflandırma modelinin performans metriklerini sunmaktadır. Model, tıbbi görüntüleme bağlamlarında "Kırıksız" ve "Kırıkk" durumlarını tespit etmek için uygulanmaktadır. Model, kırıklı vakalar için iyi bir kesinlik ve Duyarlılık ile %82.2 doğruluk oranına sahiptir. Ancak, kırıklı vakaları tespit etmede bazı zayıf yönleri göstermekte olup, bu durumun tıbbi ortamlarda önemli sonuçları olabilir. Model, tüm kırıklı vakaların %82.5'ini ve tüm kırıklı vakaların %75.6'sını doğru bir şekilde tespit etmektedir ki bu, bir kırığın gözden kaçmasının tıbbi etkilerine bağlı olarak kritik olabilir. F1 skoru, kırıklı tahminler için kesinlik ve Duyarlılık arasında iyi bir denge göstermekteyken, kırıklı tahminler için F1 skoru daha düşüktür. Modelin doğruluk oranı %79.01 olup, klinik uygulamalar için uygun bir verimlilik önermektedir.

Çizelge 5.6 %80-%20 ResNet50-FracAtlas sonuçları

DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırıksız	0.822	0.825	0.817	79.01%	5s 25ms
Kırıkk	0.799	0.756	0.751		

Şekil 5.6'da, iki bölünme modu (60%-40% ve 80%-20%) için eğri altında kalan alan (AUC) sırasıyla 0.70 ve 0.79 olarak belirtilmiştir.




Şekil 5.6 ResNet50-FracAtlas için ROC

5.5 InceptionV3-FracAtlas'ın Sonuçları

Şekil 5.7'de gösterildiği üzere, Inception v3 mimarisi sınıflandırma modeli, farklı eğitim ve doğrulama bölünmeleri (60%-40% ve 80%-20%) altında iki karışıklık matrisi göstermektedir. %60-%40 bölünmesi, yüksek sayıda gerçek negatif ile negatif vakaları etkin bir şekilde tespit ettiğini göstererek, kesinlik ve duyarlılık arasında iyi bir denge önermektedir. %80-%20 bölünmesi, burada verinin %80'i eğitim için ve %20'si doğrulama için kullanılmaktadır, hem yanlış pozitifler hem de yanlış negatifler arasında daha yüksek hata oranı göstermektedir. Gerçek pozitifler ve gerçek negatifler neredeyse eşit olsa da, yüksek sayıda yanlış negatif ve yanlış pozitif, modelin genelleştirilebilirliği ile ilgili potansiyel sorunları veya daha dengeli veriye ihtiyaç duyulduğunu göstermektedir.

Matris (a)'da model, daha doğru negatif tahminlerle sınıflar arasında daha iyi genel bir performans göstermektedir. Ancak, hem yüksek sayıda yanlış pozitifler hem de yanlış negatifler, modelin eğitim verisine aşırı uyum sağlama sorunuyla mücadele ettiğini ve bu durumun doğrulama setindeki performansını etkilediğini öne sürebilir.



Şekil 5.7 InceptionV3'ün karışıklık matrisi

%60-%40 bölünmesi, modelin tahminlerini doğrulamak için daha fazla veri sağladığından daha sağlam bir doğrulama sağlar. %80-%20 bölünmesi, daha fazla eğitim verisi sağlamasına rağmen, modelin görülmemiş verilere etkili bir şekilde genelleştirme yeteneğini engellemektedir.

Çizelge 5.7, FracAtlas veri seti üzerinde eğitilen InceptionV3 modelinin performans metriklerini sunmaktadır ve 'Kırıklı' ile 'Kırıklı' görüntüleri tespit etmeye odaklanmaktadır. Model, kırıklı görüntüleri %89.9 oranında doğru tahmin etme konusunda yüksek bir kesinlik elde etmiş, %0.900 duyarlılık ile mükemmel bir duyarlılık göstermiştir. F1 skoru olan 0.899, tıbbi görüntüleme için hayati olan kesinlik ve duyarlılık arasında güçlü bir denge göstermektedir. Model ayrıca her iki kategori üzerinden %83.7 doğruluk elde etmiştir.

Çizelge 5.7 %60-%40 InceptionV3-FracAtlas sonuçları

DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırıklı	0.899	0.900	0.899	83.7%	3s 43ms
Kırık	0.571	0.567	0.569		


Çizelge 5.8, kırık tespiti üzerine odaklanarak %80-%20 bölünmüş bir veri seti üzerinde eğitilip test edilen bir modelin performans metriklerini göstermektedir. Model, görüntüleri "Kırıklı" veya "Kırıklı" olarak sınıflandırmakta olup, kırıklı vakalar için yüksek kesinlik (%0.852) ve duyarlılık (%0.817) ile karakterize edilmektedir. F1-Skoru,

Kesinlik ve duyarlılığın ağırlıklı ortalaması olup, kırıklı vakalar için kesinlik ve duyarlılık arasında iyi bir dengeyi işaret eder ve kırıklı vakalar için yüksek bir değer olan 0.874'ü göstermektedir.

Çizelge 5.8 %80-%20 InceptionV3-FracAtlas sonuçları

DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırksız	0.852	0.85	0.874	87.90%	4s 67ms
Kırık	0.821	0.817	0.804		

Sınıflandırıcının doğruluğu yalnızca kırıklı vakalar için %87.90 olarak sağlanmıştır, bu da sınıflandırıcının genel olarak ne sıklıkla doğru olduğunu gösterir. Bu da modelin gerçek zamanlı uygulamalardaki verimliliğini gösterir. Ayrıca, ROC Şekil 5.8'de gösterilmektedir.




Şekil 5.8 InceptionV3-FracAtlas için ROC

5.6 EfficientNet v2b2-fracAtlas'ın Sonuçları

EfficientNetV2b2 modeli, iki farklı veri bölünmesinde (%60-%40 ve %80-%20) değerlendirilmektedir. Karışıklık matrisleri, vakaları pozitif veya negatif olarak sınıflandırmada modelin performansını değerlendirmek için kullanılmaktadır. Model, iki bölünme arasında performansta farklılıklar göstermektedir, bu da eğitim seti büyüklüğüne bağlı olarak genelleştirme şeklinde farklılıklar olduğunu önermektedir (Şekil 5.9).

Model, %80-%20 bölünmesinde daha yüksek yanlış pozitiflere sahip olmaktadır, bu da veri setinin daha büyük bir yüzdesinin test seti olarak ayrılmasıyla modelin daha küçük eğitim setine aşırı uyum sağladığını ve yanlış pozitif tahminlerde daha fazla olayın meydana geldiğini öne sürmektedir. Ancak, model %80-%20 bölünmesinde %60-%40 bölünmesine kıyasla gerçek pozitif vakaları yakalama konusunda daha başarılı olmaktadır. Bu, modelin hafifçe daha fazla yanlış alarm eğilimli olmasına rağmen, test seti daha büyük olduğunda gerçek pozitif vakaları kaçırma olasılığının daha düşük olduğunu önermektedir.



Şekil 5.9 EfficientNetV2b2 için karışıklık matrisi

Kesinlikteki tutarlılık, farklı bölünmelerde gözlemlendi ve bu, model pozitif tahmin yaptığında, veri seti boyutundan bağımsız olarak genellikle güvenilir olduğunu önermektedir. Bu detaylı analiz, modelin iyi performans gösterdiğini gösterirken, veri seti bölünmesinin seçiminin, genelleştirme yeteneklerini etkileyebileceğini, muhtemelen eğitim verilerinin kullanılabilirliği ve test seti zorluklarındaki farklılıklar nedeniyle belirtmektedir.

%60-%40 veri bölünmesi ile test edilen EfficientNetV2b2-FracAtlas modeli, Tablo 5.9'da gösterildiği gibi "Kırksız" ve "Kırıklı" durumları sınıflandırma yeteneği açısından analiz edilmiştir. Modelin performans metrikleri, kırksız vakalar için %93.9 doğruluk oranını belirten 0.939 kesinlik göstermektedir. Ancak, kırıklı vakalar için daha düşük bir kesinlik

sunar, bu da daha fazla yanlış pozitif olduğunu önerir. Model ayrıca daha düşük bir duyarlılık oranına sahip olup, gerçek kırıklı vakaların %40'ının kaçırıldığını gösterir. Kırksız vakalar için F1 skoru yüksek olup, güçlü bir performansı işaret ederken, kırıklı vakalar için F1 skoru daha düşüktür, bu da kesinlik ve duyarlılık arasında denge kurma zorluğunu belirtir. Modelin tahmin başına işlem süresi göreceli olarak hızlıdır.

Çizelge 5.9 %60-%40 EfficientNetV2b2-FracAtlas sonuçları


DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırksız	0.939	0.945	0.932	93.31%	3s 23 ms
Kırık	0.760	0.600	0.731		

Tablo 5.10'da gösterilen EfficientNetV2b2-FracAtlas modeli, %80-%20 veri bölünmesi kullanarak, %60-%40 bölünmesine kıyasla hem kırksız hem de kırıklı vakaların tespitinde önemli bir iyileşme göstermiştir. Model, kırksız vakaları %95.6 kesinlikle tahmin ederek gerçek negatifleri tanımlamada yüksek güvenilirlik göstermektedir. Ayrıca, az sayıda yanlış pozitif ile gerçek pozitifleri doğru bir şekilde tanımlamaktadır. Modelin kırksız vakalar için duyarlılık oranı yüksektir, tüm gerçek kırksız vakaların %95.1'ini başarıyla tespit ettiğini göstermektedir. Ayrıca, kırıklı vakalar için yüksek bir duyarlılık sergileyerek, gerçek kırıklı vakaların %94.1'ini doğru bir şekilde tanımlamaktadır. Kırksız vakalar için F1 skoru mükemmeldir, kesinlik ve duyarlılık arasında iyi bir denge göstermektedir. Kırksız tahminler için doğruluk çok yüksektir, bu kategori içinde modelin genel etkinliğini göstermektedir. Modelin işlem süresi oldukça verimlidir, büyük olasılıkla test için kullanılan veri setinin artan oranı nedeniyle işlenen veri hacminin artması sebebiyle %60-%40 bölünmesinden biraz daha yüksektir.

Çizelge 5.10 %80-%20 EfficientNetV2b2-FracAtlas sonuçları

DURUM	KESİNLİK	DUYARLILIK	F1-SCORE	DOĞRULUK	ZAMAN
Kırksız	0.956	0.951	0.954	94.9 %	3s 98ms
Kırık	0.943	0.941	0.945		

Ayrıca ROC Şekil 5.10'da gösterilmektedir.



Şekil 5.10 EfficientNetV2b2-FracAtlas için ROC

5.7 Tartışma


Çizelge 5.11, çeşitli DL modellerinin performansını, Xception, VGG16, ResNet50, InceptionV3 ve EfficientNetv2b2 dahil olmak üzere, iki farklı eğitim-test bölünmesine dayanarak karşılaştırmaktadır (%60 eğitim ve %40 test ile %80 eğitim ve %20 test). Sonuçlar, Xception'ın daha fazla eğitim verisi ile hafifçe artan doğruluğa sahip olduğunu göstermektedir, VGG16 ise daha fazla eğitim verisi ile hafifçe azalan doğruluğa sahiptir. ResNet50, daha fazla eğitim verisi ile önemli bir doğruluk düşüşü göstermekte olup, model karmaşıklığı veya eğitim verimsizlikleri ile ilgili potansiyel sorunları işaret etmektedir. InceptionV3, daha fazla eğitim verisi ile doğrulukta iyileşme göstererek sağlamlık ve ölçeklenebilirlik sergilemektedir. EfficientNetv2b2, her iki kurulumda da en iyi performans gösteren model olup, farklı veri hacimleri ve karmaşıklıkları üstün bir şekilde ele almayı sergilemektedir.

EfficientNetv2b2, zaman performansı açısından dikkate değer bir modeldir ve diğer modellere kıyasla önemli ölçüde daha düşük çıkarım süreleri sergilemektedir. Farklı eğitim-test bölünmeleri arasında hem doğruluk hem de hız açısından en verimli model olarak öne çıkan EfficientNetv2b2, makul hesaplama kaynaklarıyla yüksek performans gerektiren uygulamalarda büyük potansiyel taşımaktadır. Bu özellikleri, onu pratik uygulamalarda tercih edilen bir model haline getirmektedir. EfficientNetv2b2, yüksek doğruluk ve hız kombinasyonu, çeşitli veri kümelerinde üstün performans sergileyerek, daha geniş bir kullanım yelpazesi sunmaktadır.


Çizelge 5.11 %60-%40 ve %80-%20 FracAtlas'ta değerlendirilen sonuçlar

MODELİ	DOĞRULUK %	ZAMAN (ms)	ROC
%60 Eğitim - %40 Teste Göre Performans Gösterilmektedir			
Xception	85	5s 61ms	0.68
VGG16	86	3s 77ms	0.72
ResNet50	77.7	5s 02ms	0.70
InceptionV3	83.7	3s 43ms	0.72
EfficientNetv2b2	93.31	3s 23ms	0.73
%80 Eğitim - %20 Teste Göre Performans Gösterilmektedir			
Xception	85.53	7s 57ms	0.70
VGG16	85.61	4s 98ms	0.88
ResNet50	71.01	5s 25 ms	0.79
InceptionV3	87.78	4s 67ms	0.81
EfficientNetv2b2	94.91	3s 98ms	0.95

Çalışma, EfficientNetv2b2'nin yüksek performans ve verimlilik senaryoları için en optimal seçim olduğunu ortaya koymaktadır; en yüksek doğruluğu ve en düşük işlem süresini sunmaktadır. VGG16, doğruluk ve işlem süresi arasında bir denge sağlamaktadır. EfficientNetv2b2'nin üstün performansı, yüksek doğruluk ve hızlı işlem gerektiren durumlar için mükemmel bir seçim yapmaktadır, diğer modeller ise gereken doğruluk ve hesaplama maliyeti dengesine bağlı olarak uygun olabilir. Şekil 5.11 ve Şekil 5.12, değerlendirilen sonuçların grafiklerini göstermektedir.



Şekil 5.11 Değerlendirilen sonuçları göstermektedir (Eğitimde %60, testte %40) doğruluk oranı



Şekil 5.12 Değerlendirilen sonuçları göstermektedir (Eğitimde %80, testte %20) doğruluk oranı

5.8 Çalışmanın Sonuçlarının Önceki Çalışmalarla Karşılaştırılması

Farklı çalışmalarda çeşitli DL modellerinin performanslarının karşılaştırılmasında, EfficientNetv2b2 modeli mevcut analizde özellikle yüksek doğruluk ve ROC AUC skorları ile dikkat çekmektedir. Özellikle, %60 eğitim ve %40 test içeren bir veri bölünmesinde EfficientNetv2b2, %93.31 doğruluk ve 0.73 ROC AUC elde etmiştir. Eğitim verisi %80'e çıkarıldığında, modelin doğruluğu %94.91'e yükselmiş ve ROC AUC 0.95 olmuştur. Bu, EfficientNetv2b2'nin daha fazla veri ile etkin bir şekilde ölçeklendirildiğini ve güçlü genelleştirme yetenekleri sergilediğini önermektedir.

Çizelge 5.12 karşılaştırmasında, önceki çalışmalar, Inception-ResNet ve CNN gibi modellerden iyi performanslar göstermektedir. Örneğin, Inception-ResNet, önceki çalışmalarda sırasıyla %91.2 doğruluk ve 0.918 ROC AUC ile en yüksek skorları kaydetmiştir. Bu, performansı artırmak için farklı ağ stratejilerini birleştiren hibrit mimarilerin etkinliğini vurgulamaktadır. Buna karşın, Bagaria *et al.* (2021) tarafından kullanılan CNN, %90 gibi sağlam bir doğruluk göstermiş ancak daha düşük 0.808 ROC AUC ile model sağlamlığı veya sınıf dengesi konusunda potansiyel sorunları işaret etmiştir.

Çizelge 5.12 Çalışmanın sonuçlarının önceki çalışmalarla karşılaştırılması

İLGİLİ ÇALIŞMALAR		MODELİ	DOĞRULUK	ROC
Şahin (2023)		Linear discriminant analysis LDA	88.67 %	0.89
Bagaria <i>et al.</i> (2021)		CNN	90 %	0.808
Nguyen <i>et al.</i> (2021)		YOLOv4	81.91%	-
Thian <i>et al.</i> (2019)		Inception-ResNet	91.2%	0.918
Bu Çalışmada	Eğitimde %60, testte %40 doğruluk oranı	Xception	85 %	0.68
		VGG16	86 %	0.72
		ResNet50	77.7 %	0.70
		InceptionV3	83.7 %	0.72
		EfficientNetv2b2	93.31 %	0.73
	Eğitimde %80, testte %20 doğruluk oranı	Xception	85.53 %	0.70
		VGG16	85.61 %	0.88
		ResNet50	71.01 %	0.79
		InceptionV3	87.78 %	0.81
		EfficientNetv2b2	94.91 %	0.95

Diğer modeller gibi Lineer Diskriminant Analizi (LDA) ve YOLOv4 de çeşitli sonuçlar sundu. Basitliğine rağmen LDA, 0.89 ROC AUC elde etti ve bu, doğrusal ayrılabilirliğin yeterli olduğu belirli sınıflandırma görevleri için uygunluğunu vurguladı. Gerçek zamanlı nesne tespiti için özelleştirilen YOLOv4 ise %81.91 doğrulukla geride kaldı ve ROC AUC bildirilmedi, bu da genelleştirilmiş sınıflandırma görevleri için optimal olmayabileceğini öne sürdü. Tablo 5.12, önerilen önceki çalışmalarla bulguların özetini göstermektedir. Bu çalışmada kullanılan EfficientNetv2b2, analiz edilenler arasında üstün model olarak ortaya çıkmakta, hem yüksek doğruluk hem de farklı veri dağılımları arasında sınıflar arasında mükemmel ayırım yapma yeteneği sergilemektedir.

6. SONUÇ VE ÖNERİLER

Çalışma boyunca, Xception-FracAtlas, VGG16-FracAtlas, ResNet50-FracAtlas, InceptionV3-FracAtlas ve EfficientNetv2b2-FracAtlas olmak üzere birkaç CNN mimarisi karşılaştırıldı. Bu modeller, kesinlik, duyarlılık, F1-puanı, genel doğruluk ve çıkarım süresi gibi kritik performans metrikleri temelinde değerlendirilmektedir ve her model, Kırık kemik olmayan ve Kırık kemik olan durumlar olarak sınıflandırılan X-ray görüntülerini içeren veri seti test edilmektedir. Bulgularımız, EfficientNetv2b2-FracAtlas'ın yüksek bir performans sergilediğini, kesinlik, Kırık kemik durumları için F1-puanı ve genel doğrulukta üstün olduğunu ve hız ile hesaplama verimliliği arasında takdire şayan bir denge sağladığını ortaya koymaktadır. Bu, modelin kemik kırıklarını doğru bir şekilde tespit etme yeteneğinin derinliğini vurgulamakta ve hızlı ve kesin teşhisin hayati olduğu klinik ortamlara entegrasyon için onu birinci sınıf bir aday yapmaktadır. Diğer yandan, VGG16-FracAtlas ve Xception-FracAtlas gibi diğer modeller, Kırık kemik olmayan durumlar için duyarlılık ve çıkarım hızı gibi belirli metriklerde umut verici sonuçlar gösterse de, EfficientNetv2b2-FracAtlas tarafından sergilenen kapsamlı performansın gerisinde kalmaktadır. Yine de, bu modeller, CNN mimarilerinin çeşitli yeteneklerine ve tıbbi görüntü analizindeki potansiyel uygulamalarına dair değerli içgörüler sunmaktadır. Çalışmamız, X-ray görüntülerinden kemik kırıklarının tespitinde DL yöntemlerinin yüksek verimlilik potansiyelini vurgulamaktadır. Böyle otomatik sistemlerin devreye alınması, tanı süreçlerini önemli ölçüde geliştirebilir, insan hatasının olasılığını azaltabilir ve hızlı ve doğru tıbbi bakım sağlanmasını kolaylaştırabilir. Ayrıca, daha geniş bir tıbbi görüntüleme görev yelpazesine hitap etmek için DL modellerinin optimizasyonu ve özelleştirilmesi konusunda daha fazla araştırma yapılması için de yollar açmaktadır. Kemik kırığı tespiti ve teşhisindeki öneriler, optimizasyon, veri seti genişletme, çok modlu yaklaşımlar, klinik entegrasyon, açıklanabilirlik ve yorumlanabilirlik üzerine odaklanmalıdır. Bu alanlar, modellerin genelleştirme yeteneklerini artırmayı, daha büyük bir veri seti eklemeyi, çok modlu yaklaşımları keşfetmeyi, DL modellerini klinik iş akışlarına entegre etmeyi ve açıklanabilirlik ile yorumlanabilirliği iyileştirmeyi içermektedir.

KAYNAKLAR

- Abdedeen, I., Rahman, M. A., Fatema Zohra Prottyasha, Ahmed, T., Chowdhury, T. M., & Shatabda, S. 2023. FracAtlas: A dataset for fracture classification, localization and segmentation of musculoskeletal radiographs. *Scientific Data*, 10(1). <https://doi.org/10.1038/s41597-023-02432-4>
- Ashkani-Esfahani, S., Mojahed Yazdi, R., Bhimani, R., Kerkhoffs, G. M., Maas, M., DiGiovanni, C. W., Lubberts, B., & Guss, D. 2022. Detection of ankle fractures using deep learning algorithms. *Foot and Ankle Surgery*, 28(8): 1259–1265. <https://doi.org/10.1016/j.fas.2022.05.005>
- Badgeley, M. A., Zech, J. R., Oakden-Rayner, L., Glicksberg, B. S., Liu, M., Gale, W., McConnell, M. V., Percha, B., Snyder, T. M., & Dudley, J. T. 2019. Deep learning predicts hip fracture using confounding patient and healthcare variables. *Npj Digital Medicine*, 2(1). <https://doi.org/10.1038/s41746-019-0105-1>
- Bagaria, R., Wadhwani, S., & Wadhwani, A. K. 2021. Bone fracture detection in x-ray images using convolutional neural network. *Soft Computing Research Society EBooks*, 459–466. <https://doi.org/10.52458/978-93-91842-08-6-43>
- Bahmei, B., Birmingham, E., & Arzanpour, S. 2022. CNN-RNN and data augmentation using deep convolutional generative adversarial network for environmental sound classification. *IEEE Signal Processing Letters*, 1–1. <https://doi.org/10.1109/lsp.2022.3150258>
- Bandyopadhyay, O., Biswas, A., & Bhattacharya, B. B. 2014. Long-Bone fracture detection in digital x-ray images based on concavity index. *Lecture Notes in Computer Science*, 212–223. https://doi.org/10.1007/978-3-319-07148-0_19
- BOESCH, G. 2021 .Website: <https://viso.ai/deep-learning/vgg-very-deep-convolutional-networks/>. Date of access: 06.10.2021.
- Buffer, O., Pietquin, O., & Weng, P. 2007. Reinforcement learning. *Computational Intelligence*, 83–91. <https://doi.org/10.1002/9780470512517.ch6>
- Chen, Y.-C., Chou, C.-T., & Wang, Y.-C. F. 2020. Learning to learn in a semi-supervised fashion. *Lecture Notes in Computer Science*, 460–478. https://doi.org/10.1007/978-3-030-58523-5_27

- Cheng, Z., Wang, S., Zhang, P., Wang, S., Liu, X., & Zhu, E. 2021. Improved autoencoder for unsupervised anomaly detection. 36(12): 7103–7125. <https://doi.org/10.1002/int.22582>
- Chollet, F. 2017. Xception: Deep learning with depthwise separable convolutions. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1251–1258.
- Dai, J., Lu, Y., & Wu, Y. N. 2016. Generative modeling of convolutional neural networks. Statistics and Its Interface, 9(4): 485–496. <https://doi.org/10.4310/sii.2016.v9.n4.a8>
- DEV, D. 2022. Website: <https://www.opaortho.com/types-of-bone-fractures/>. Date of access 22.11.2022.
- Dlshad , A. K., & Hawezi, R. 2023. Detection of image processing fracture based on machine learning techniques. Measurement: Sensors, 100723. <https://doi.org/10.1016/j.measen.2023.100723>
- Gomes, H. M., Grzenda, M., Mello, R., Read, J., Le Nguyen, M. H., & Bifet, A. 2022. A survey on semi-supervised learning for delayed partially labelled data streams. ACM Computing Surveys. <https://doi.org/10.1145/3523055>
- GOOGLE. 2018. Website: <https://cloud.google.com/tpu/docs/inception-v3-advanced#:~:text=Inception%20v3%20is%20an%20image>. Date of access: 10.02.2018
- Guan, B., Yao, J., Wang, S., Zhang, G., Zhang, Y., Wang, X., & Wang, M. 2022. Automatic detection and localization of thighbone fractures in X-ray based on improved deep learning method. Computer Vision and Image Understanding, 216: 103345. <https://doi.org/10.1016/j.cviu.2021.103345>
- Hardalaç, F., Uysal, F., Peker, O., Çiçeklidağ, M., Tolunay, T., Tokgöz, N., Kutbay, U., Demirciler, B., & Mert, F. 2022. Fracture detection in wrist x-ray images using deep learning-based object detection models. Sensors, 22(3): 1285. <https://doi.org/10.3390/s22031285>
- Hu, M., Zhang, J., Matkovic, L., Liu, T., & Yang, X. 2022. Reinforcement learning in medical image analysis: Concepts, applications, challenges, and future directions. Journal of Applied Clinical Medical Physics, 24(2). <https://doi.org/10.1002/acm2.13898>

- Ju, R.-Y., & Cai, W. 2023. Fracture detection in pediatric wrist trauma x-ray images using yolov8 algorithm. Scientific Reports, 13(1): 20077. <https://doi.org/10.1038/s41598-023-47460-7>
- Khatik, I., & Kadam, S. 2022. A systematic review of bone fracture detection models using convolutional neural network approach. Journal of Pharmaceutical Negative Results, 153–158. <https://doi.org/10.47750/pnr.2022.13.s09.019>
- KHUONG, B. 2020. Website: <https://pub.towardsai.net/whirlwind-tour-of-rnns-a11effb7808f?gi=e186b254ca8e>. Date of access: 11.06.2020
- Kraus, M., Anteby, R., Konen, E., Eshed, I., & Klang, E. 2023. Artificial intelligence for X-ray scaphoid fracture detection: a systematic review and diagnostic test accuracy meta-analysis. European Radiology. <https://doi.org/10.1007/s00330-023-10473-x>
- Kundu, N. 2023. Website: <https://medium.com/@nitishkundu1993/exploring-resnet50-an-in-depth-look-at-the-model-architecture-and-code-implementation-d8d8fa67e46f#:~:text=ResNet50%20is%20a%20deep%20convolutional>. Date of access: 15.05.2023
- Marhon, S. A., Cameron, C. J. F., & Kremer, S. C. 2013. Recurrent neural networks. Intelligent Systems Reference Library, 29–65. https://doi.org/10.1007/978-3-642-36657-4_2
- Mathew, A., Amudha, P., & Sivakumari, S. 2020. Deep learning techniques: An overview. Advances in Intelligent Systems and Computing, 1141: 599–608. https://doi.org/10.1007/978-981-15-3383-9_54
- McNicholas, P. D., & Tait, P. A. 2019. Unsupervised learning. Chapman and Hall/CRC EBooks, 129–164. <https://doi.org/10.1201/9781351013673-6>
- Meena, T., & Roy, S. 2022. Bone fracture detection using deep supervised learning from radiological images: A paradigm shift. Diagnostics, 12(10): 2420. <https://doi.org/10.3390/diagnostics12102420>
- Ming, Y., Cao, S., Zhang, R., Li, Z., Chen, Y., Song, Y., & Qu, H. 2017. Understanding hidden memories of recurrent neural networks. IEEE Xplore. <https://doi.org/10.1109/VAST.2017.8585721>
- MINGXING, T. 2019 . Website: <https://blog.research.google/2019/05/efficientnet-improving-accuracy-and.html?m=1>. Date of access: 29.03.2019.

- Nguyen, H. P., Hoang, T. P., & Nguyen, H. H. 2021. A deep learning based fracture detection in arm bone x-ray images. *IEEE Xplore*. <https://doi.org/10.1109/MAPR53640.2021.9585292>
- Nichols, J. A., Herbert Chan, H. W., & Baker, M. A. B. 2018. Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophysical Reviews*, 11(1): 111–118. <https://doi.org/10.1007/s12551-018-0449-9>
- Polson, N. G., & Sokolov, V. O. 2019. Deep learning. *Semantic Scholar*, 1–12. <https://doi.org/10.1002/9781118445112.stat08171>
- Purwono, P., Ma'arif, A., Rahmaniar, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & Haq, Q. M. ul. 2023. Understanding of convolutional neural network (CNN): A review. *International Journal of Robotics and Control Systems*, 2(4): 739–748. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Rahman, T., Chowdhury, M. E. H., Khandakar, A., Islam, K. R., Islam, K. F., Mahbub, Z. B., Kadir, M. A., & Kashem, S. 2020. Transfer learning with deep convolutional neural network (CNN) for pneumonia detection using chest x-ray. *Applied Sciences*, 10(9): 3233. <https://doi.org/10.3390/app10093233>
- Sahin, M. E. 2023. Image processing and machine learning-based bone fracture detection and classification using x-ray images. <https://doi.org/10.1002/ima.22849>
- Saxena, D., & Cao, J. 2021. Generative Adversarial Networks (GANs). *ACM Computing Surveys*, 54(3): 1–42. <https://doi.org/10.1145/3446374>
- Sindhu Meena, K., & Suriya, S. 2020. A survey on supervised and unsupervised learning techniques. *Proceedings of International Conference on Artificial Intelligence, Smart Grid and Smart City Applications*, 627–644. https://doi.org/10.1007/978-3-030-24051-6_58
- STEWART, M. 2020. Website: <https://towardsdatascience.com/generating-images-with-autoencoders-77fd3a8dd368>. Date of Access: 31.01.2020.
- Su, Z., Adam, A., Nasrudin, M. F., Ayob, M., & Punganan, G. 2023. Skeletal fracture detection with deep learning: A comprehensive review. *Diagnostics*, 13(20): 3245. <https://doi.org/10.3390/diagnostics13203245>
- Su, Z., Adam, A., Nasrudin, M. F., Ayob, M., & Punganan, G. 2023. Skeletal fracture detection with deep learning: a comprehensive review. *Diagnostics*, 13(20): 3245. <https://doi.org/10.3390/diagnostics13203245>

- Syed, I., & Lokhande, V. 2024. An overview of the supervised machine learning. International Research Journal of Modernization in Engineering Technology and Science. <https://doi.org/10.56726/irjmets51366>
- Tanzi, L., Vezzetti, E., Moreno, R., & Moos, S. 2020. X-Ray bone fracture classification using deep learning: A baseline for designing a reliable approach. Applied Sciences, 10(4): 1507. <https://doi.org/10.3390/app10041507>
- Thian, Y. L., Li, Y., Jagmohan, P., Sia, D., Chan, V. E. Y., & Tan, R. T. 2019. Convolutional neural networks for automated fracture detection and localization on wrist radiographs. Radiology: Artificial Intelligence, 1(1): e180001. <https://doi.org/10.1148/ryai.2019180001>
- Vermeulen, A. F. 2019. Unsupervised learning: deep learning. Apress EBooks, 225–241. https://doi.org/10.1007/978-1-4842-5316-8_8
- Yeh, L.-R., Zhang, Y., Chen, J.-H., Liu, Y.-L., Wang, A.-C., Yang, J.-Y., Yeh, W.-C., Cheng, C.-S., Chen, L.-K., & Su, M.-Y. 2022. A deep learning-based method for the diagnosis of vertebral fractures on spine MRI: retrospective training and validation of ResNet. European Spine Journal, 31(8): 2022–2030. <https://doi.org/10.1007/s00586-022-07121-1>
- Zhu, L., Chen, Y., Ghamisi, P., & Benediktsson, J. A. 2018. Generative Adversarial Networks for Hyperspectral Image Classification. IEEE Transactions on Geoscience and Remote Sensing, 56(9): 5046–5063. <https://doi.org/10.1109/tgrs.2018.2805286>

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı ve Soyadı : Aran Mahdi Zen Alabdeen ZEN ALABDEEN

Eğitim

Yüksek Lisans Çankırı Karatekin Üniversitesi 2021-2024
Fen Bilimleri Enstitüsü
Elektronik ve Bilgisayar Mühendisliği
Anabilim Dalı

Lisans Al-Qalam University College 2003-2007
Mühendislik Fakültesi
Bilgisayar Mühendisliği Anabilim Dalı