



T.C.
İZMİR KÂTİP ÇELEBİ ÜNİVERSİTESİ
TIP FAKÜLTESİ
ACİL TIP ANABİLİM DALI

TİBİA PLATO KIRIKLARININ YAZILIM ALGORİTMASI
KULLANILARAK YORUMLANMA BAŞARISI

Burak ACAR
ORCID ID: 0000-0002-3672-8787
UZMANLIK TEZİ

TEZ DANIŞMANI
DOÇ. DR. UMUT PAYZA
YARDIMCI TEZ DANIŞMANI
DOÇ. DR. MEHMET GÖKTUĞ EFGAN

İZMİR-2025

T.C.
İZMİR KÂTİP ÇELEBİ ÜNİVERSİTESİ
TIP FAKÜLTESİ
ACİL TIP ANABİLİM DALI

TİBİA PLATO KIRIKLARININ YAZILIM ALGORİTMASI
KULLANILARAK YORUMLANMA BAŞARISI

Burak ACAR
ORCID ID: 0000-0002-3672-8787
UZMANLIK TEZİ

TEZ DANIŞMANI
DOÇ. DR. UMUT PAYZA
YARDIMCI TEZ DANIŞMANI
DOÇ. DR. MEHMET GÖKTUĞ EFGAN

İZMİR, 2025

KABUL VE ONAY SAYFASI

Tıp Fakültesi;

İzmir Kâtip Çelebi Üniversitesi Tıp Fakültesi Anabilim Dalı Uzmanlık Programı tarafından yürütülmüş olan “**Tibia Plato Kırıklarının Yazılım Algoritması Kullanılarak Yorumlanma Başarısı**” başlıklı bu çalışma, aşağıdaki jüri tarafından Uzmanlık Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 16/04/2025

Tez Danışmanı: Doç. Dr. Umut PAYZA

0000-0002-5297-1066

İzmir Kâtip Çelebi Üniversitesi

Üye: Doç. Dr. Umut PAYZA

0000-0002-5297-1066

İzmir Kâtip Çelebi Üniversitesi

Üye: Doç. Dr. Mehmet Göktuğ EFGAN

0000-0002-0794-1239

İzmir Kâtip Çelebi Üniversitesi

Üye: Doç. Dr. Hüseyin ACAR

0000-0002-1905-7133

İzmir Kâtip Çelebi Üniversitesi

Yedek Üye: Prof. Dr. Zeynep KARAKAYA

0000-0003-0562-8297

İzmir Kâtip Çelebi Üniversitesi

Yedek Üye: Doç. Dr. Ejder Saylav BORA

0000-0002-2448-2337

İzmir Kâtip Çelebi Üniversitesi

ONAY: Bu Uzmanlık tezi, Eğitim Planlama Kurulu'na belirlenen yukarıdaki jüri üyeleri tarafından uygun görülmüş ve kabul edilmiştir.

İmza

Prof. Dr. Tuğrul Bulut

Dekan

İÇİNDEKİLER

KABUL VE ONAY SAYFASI.....	IV
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI	VII
ETİK BEYAN	VIII
TEŞEKKÜR	IX
ÖZET	X
ABSTRACT	XII
KISALTMALAR	XIV
ŞEKİLLER	XVI
TABLolar	XVIII
1. GİRİŞ	1
2. GENEL BİLGİLER.....	3
2.1. Diz Anatomisi	3
2.2. Tibia Plato Anatomisi	4
2.2.1. Tibia Plato Kemik Anatomisi.....	4
2.2.2. Tibia Plato Ligamentöz Anatomisi	5
2.2.3. Tibia Plato Anatomisinin Klinik Önemi	6
2.3. Tibia Plato Kırıkları	6
2.3.1. Tibia Plato Kırıkları Tanımı.....	6
2.3.2. Tibia Plato Kırıkları Sınıflandırmaları	7
2.3.3. Tibia Plato Kırıkları Tanı ve Görüntüleme	10
2.3.4. Tibia Plato Kırıkları Tedavi	11
2.3.5. Tibia Plato Kırıklarında Tedavi Sonrası Prognoz	12
2.4. Yapay Zeka, Makine Öğrenme ve Derin Öğrenme	14
2.4.1. Yapay Zeka	14
2.4.2. Makine Öğrenmesi	15
2.4.2.1. Denetimli Öğrenme	15
2.4.2.2. Denetimsiz Öğrenme.....	16
2.4.2.3. Pekiştirmeli Öğrenme.....	16
2.4.2.4. Destek Vektör Makinesi (DVM) Sınıflandırıcı.....	16
2.4.3. Yapay Sinir Ağı.....	17
2.4.3.1. Yapay Sinir Ağlarının Genel Özellikleri.....	17
2.4.3.2. Yapay Sinir Ağlarının Kullanım Alanları	17
2.4.3.3. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	17
2.4.3.3.1. Biyolojik Sinir Hücresi.....	18

2.4.3.3.2. Yapay Sinir Hücresi	18
2.4.3.4. Yapay Sinir Ağlarının Sınıflandırılması	19
2.4.3.4.1. İleri Beslemeli Yapay Sinir Ağları.....	19
2.4.3.4.2. Geri Beslemeli Yapay Sinir Ağları	20
2.4.4. Derin Öğrenme	20
2.4.4.5. Literatürde Sık Kullanılan Derin Öğrenme Mimarileri	26
2.4.4.5.1 AlexNet	26
2.4.4.5.2. ResNet.....	27
2.4.4.5.3. MobileNet.....	29
3. GEREÇ VE YÖNTEM	31
3.1. Çalışma Tasarımı	31
3.2. Çalışma Popülasyonu.....	31
3.3. Çalışma Dizaynı.....	31
3.4. Veri Kümesi, Veri Ön İşleme ve Tibia Plato Kırığı Tespit Mimarisi.....	32
3.4.1. Görüntü Aşamasında Birleştirme	33
3.4.2. Öznitelik Aşamasında Birleştirme	34
3.5. Çalışmada Kullanılan Performans Metrikleri	35
3.6. Çalışmada Kullanılan Hiper-Parametreler	37
4. BULGULAR	39
4.1. Görüntü Aşamasında Birleştirme.....	39
4.2. Öznitelik Aşamasında Birleştirme	45
5. TARTIŞMA	50
5.1. Kısıtlılıklar	53
6. SONUÇ VE ÖNERİLER	55
7. KAYNAKLAR.....	56
EKLER	62
ÖZGEÇMİŞ.....	64

TEŞEKKÜR

Eđitim sürecinde bilgileri ve tecrübeleri ile her zaman bana yol gösterip yoluma ışık tutan hocalarım Prof. Dr. Fatih Esad TOPAL'a, Prof. Dr. Zeynep KARAKAYA'ya, Doç. Dr. Umut PAYZA'ya, Doç. Dr. Adnan YAMANOĐLU'na, Doç. Dr. Serkan BİLGİN'e, Doç. Dr. Hüseyin ACAR'a, Doç. Dr. Ahmet KAYALI'ya, Doç. Dr. Ejder Saylav BORA'ya, Doç. Dr. Mehmet Göktuđ EFGAN'a, Doç. Dr. Osman Sezer ÇINAROĐLU'na, Doç. Dr. Güner YURTSEVER'e, Doç. Dr. Pınar Yeşim AKYOL'a, Uzm. Dr. Ecem Ermete GÜLER'e, Uzm Dr. Süleyman KIRIK'a,

Hem dönem arkadaşım, hem kıdemlim, hem uzmanım olan en yakın arkadaşım Uzm. Dr. Efe KANTER'e,

Pratisyenliğimde acil servisi sevdiren ve Acil Tıp yazmama vesile olan Uzm. Dr. Güney Yılmaz ERTÖRER'e

Hep birlikte çıktığımız zorlu yolda sırt sırta verip keyif alarak çalıştığım eş kıdemlerim Dr. Dilara DAYIOĐLU, Dr. Bahar KALE, Dr. Aşkim KEŞİR, Dr. Tutku Duman ŞAHAN, Dr. Alperen Mehmet ŞAHİN, Dr. İsmail Anıl CANDAŞ, Dr. Hakan İYİSARAÇ, Dr. Arif Türker MERT'e; her nöbet beraber ter döktüğümüz tüm hekim arkadaşlarım ile acil servis personeline;

Her zaman yanımda olan, beni benden daha çok düşünen, bugünlere gelmem için dişini tırnağına takan, her şeyden çok sevdiğim canım ailem; Eliz ACAR, Naime Hülya Tiftikçi ACAR, Fatma ACAR, Mülayim ACAR, Zeliha ACAR ve Eylül ACAR'a

Sonsuz teşekkürler...

Dr. Burak ACAR

ÖZET

TİBİA PLATO KIRIKLARININ YAZILIM ALGORİTMASI KULLANILARAK YORUMLANMA BAŞARISI

Burak ACAR

**İzmir Kâtip Çelebi Üniversitesi Atatürk Eğitim ve Araştırma Hastanesi Acil Tıp
Anabilim Dalı Uzmanlık Tezi, İzmir, Türkiye, 2025**

Giriş ve Amaç: Tibia plato kırıkları, diz eklemine yük taşıma fonksiyonunu ve stabilitesini etkileyen önemli ortopedik yaralanmalardır. Yüksek enerjili travmalar veya osteoporozlu bireylerde düşük enerjili travmalar sonucu oluşabilir. Doğru sınıflandırma ve uygun tedavi seçimi, fonksiyonel sonuçları doğrudan etkilemektedir.

Geleneksel görüntüleme ve manuel sınıflandırma yöntemleri subjektif değerlendirmelere bağlı olduğundan hata payı yüksektir. Bu çalışmada, tibia plato kırıklarının yazılım algoritmaları ile otomatik analiz edilmesi ve farklı derin öğrenme modellerinin tanılma başarısının karşılaştırılması amaçlanmıştır. Böylece klinik karar süreçlerinde daha hızlı ve objektif değerlendirme sağlanması hedeflenmiştir.

Gereç ve Yöntem: Bu retrospektif çalışma, acil servise başvuran ve tibia plato kırığı ön tanısı alan olguların radyografik görüntülerinin yapay zeka destekli derin öğrenme algoritmaları ile değerlendirilmesini amaçlamaktadır. Son 15 yıl içinde İzmir Katip Çelebi Üniversitesi Atatürk Eğitim ve Araştırma Hastanesi acil servisine başvuran, 18 yaş ve üzeri, tibia plato kırığı ön tanısı almış 317 hasta ile kontrol grubundaki 339 hasta çalışmaya dahil edilmiştir. Eksik verisi bulunan hastalar, 18 yaş altı bireyler, ileri gonartrozu olanlar ve gebeler çalışma dışı bırakılmıştır.

Hastaların diz ön-arka (AP) ve yan (lateral) standart radyografileri, hastane bilgi yönetim sisteminden (HBYS) JPEG formatında elde edilmiştir. Görüntüler, AlexNet, ResNet18, ResNet50, ResNet101 ve MobileNet gibi evrişimli sinir ağı (CNN) mimarileri ile eğitilerek tibia plato kırığı tanısında en doğru yaklaşım belirlenmiştir.

İki farklı derin öğrenme yöntemi kullanılmıştır:

Görüntü aşamasında birleştirme: Ön-arka ve yan X-ray görüntülerinin birleştirilerek eğitilmesi.

Öz nitelik aşamasında birleştirme: Ön-arka ve yan görüntülerin ayrı ayrı eğitilip, elde edilen derin öz niteliklerin birleştirilerek sınıflandırılması.

Eğitilen modeller, doğruluk, duyarlılık ve özgüllük gibi performans ölçütleri açısından karşılaştırılmıştır.

Bulgular: Çalışmada, tibia plato kırığı tanısında farklı derin öğrenme modellerinin performansları karşılaştırılmıştır. Toplam 317 tibia plato kırıklı hasta ve 339 kontrol grubunun radyografileri analiz edilerek AlexNet, ResNet18, ResNet50, ResNet101 ve MobileNet gibi evrişimli sinir ağı (CNN) mimarileri test edilmiştir.

Eğitim ve test veri performanslarının tutarlılığı, yüksek doğruluk oranı ve hızlı eğitilebilirliği nedeniyle ResNet18, en başarılı model olarak belirlenmiştir. Görüntü aşamasında birleştirme yöntemi, ResNet18 için en yüksek doğruluğa ulaşmıştır (ACC %93.90, SEN %89.60, SPE %98.00, PPV %97.70, FDR %2.30). Buna karşın, öz nitelik aşamasında birleştirme yöntemi daha düşük doğruluk oranı göstermiştir (ACC %87.82, SEN %87.37, SPE %88.24, PPV %87.37, FDR %12.63).

Sonuçlar: Bu çalışmada, tibia plato kırıklarının tanısında yapay zeka tabanlı derin öğrenme modellerinin etkinliği değerlendirilmiş ve karşılaştırılmıştır. Analizler sonucunda ResNet18 modeli en yüksek doğruluğa ulaşmış, görüntü aşamasında birleştirme yöntemi en başarılı sonuçları vermiştir.

Geleneksel kırık değerlendirmeleri zaman alıcı ve subjektif olabilirken, yapay zeka destekli sistemler süreci hızlandırarak objektifliği artırmaktadır. Bulgularımız, derin öğrenme modellerinin klinik kullanıma entegrasyonunun, tibia plato kırıklarının daha hızlı ve doğru teşhis edilmesine katkı sağlayabileceğini göstermektedir.

Gelecekte veri setlerinin genişletilmesi ve algoritmaların daha fazla klinik değişkenle desteklenmesi, yapay zeka modellerinin ortopedik travma tanısındaki rolünü güçlendirebilir. Bu nedenle, klinik karar destek sistemlerine entegrasyonu için daha fazla çalışma gerekmektedir.

Anahtar Kelimeler: Tibia plato kırıkları, Evrişimsel sinir ağları (CNN), ResNet, Derin öğrenme, Makine öğrenmesi, Yapay zeka

ABSTRACT

SUCCESS IN INTERPRETING TIBIA PLATEAU FRACTURES USING SOFTWARE ALGORITHM

Burak ACAR

**Izmir Kâtip Celebi University Atatürk Training and Research Hospital Emergency
Medicine Department Specialization Thesis, Izmir, Türkiye, 2024**

Introduction and Objective: Tibial plateau fractures are significant orthopedic injuries that affect the knee joint's load-bearing function and stability. They may result from high-energy trauma or low-energy trauma in osteoporotic individuals. Accurate classification and appropriate treatment selection directly influence functional outcomes.

Traditional imaging and manual classification methods rely on subjective evaluations, leading to a high margin of error. This study aims to enable the automatic analysis of tibial plateau fractures using software algorithms and compare the diagnostic performance of different deep learning models. The goal is to facilitate faster and more objective assessments in clinical decision-making processes.

Materials and Methods: This retrospective study aimed to evaluate the radiographic images of patients presenting to the emergency department with a preliminary diagnosis of tibial plateau fractures using artificial intelligence-supported deep learning algorithms. The study included 317 patients diagnosed with tibial plateau fractures and 339 control subjects who presented to the emergency department of İzmir Katip Çelebi University Atatürk Training and Research Hospital within the last 15 years. Patients with missing data, those under 18 years of age, individuals with advanced gonarthrosis, and pregnant women were excluded.

Standard anteroposterior (AP) and lateral knee radiographs were obtained in JPEG format from the hospital information management system (HBYS). These images were processed using convolutional neural network (CNN) architectures such as AlexNet, ResNet18, ResNet50, ResNet101, and MobileNet to determine the most accurate approach for diagnosing tibial plateau fractures.

Two different deep learning approaches were utilized:

Image-level fusion: Combined training of AP and lateral X-ray images.

Feature-level fusion: Independent training of AP and lateral images, followed by the fusion of extracted deep features for classification.

The trained models were compared based on performance metrics such as accuracy, sensitivity, and specificity.

Results: The study compared the performance of different deep learning models in diagnosing tibial plateau fractures. A total of 317 patients with tibial plateau fractures and 339 control subjects were analyzed using convolutional neural network (CNN) architectures, including AlexNet, ResNet18, ResNet50, ResNet101, and MobileNet.

ResNet18 was identified as the most successful model due to its consistency in training and test performance, high accuracy, and faster training capability. The image-level fusion method achieved the highest accuracy with ResNet18 (ACC: 93.90%, SEN: 89.60%, SPE: 98.00%, PPV: 97.70%, FDR: 2.30%). In contrast, the feature-level fusion method yielded lower accuracy (ACC: 87.82%, SEN: 87.37%, SPE: 88.24%, PPV: 87.37%, FDR: 12.63%).

Conclusion: This study evaluated and compared the effectiveness of artificial intelligence-based deep learning models in diagnosing tibial plateau fractures. The analysis identified ResNet18 as the most accurate model, with the image-level fusion method yielding the best results.

Traditional fracture assessment methods can be time-consuming and subjective, whereas AI-assisted systems enhance efficiency and objectivity. Our findings suggest that integrating deep learning models into clinical practice may facilitate faster and more accurate diagnosis of tibial plateau fractures.

Expanding datasets and incorporating additional clinical variables in the future could further strengthen the role of AI models in orthopedic trauma diagnosis. Therefore, further research is needed to integrate these technologies into clinical decision support systems.

Keywords: Tibial plateau fractures, Convolutional Neural Networks (CNN), ResNet, Deep learning, Machine learning, Artificial intelligence

KISALTMALAR

ACC:	Doğruluk
ACL:	Anterior Çapraz Bağ
AO/OTA:	Arbeitsgemeinschaft für Osteosynthesefragen/Orthopaedic Trauma Association
AP:	Antero-Posterior (Ön-Arka)
ARİF:	Açık Redüksiyon ve İnternal Fiksasyon
BT:	Bilgisayarlı Tomografi
CNN:	Convolutional Neural Network (Evrışimli Sinir Ağı)
CombF:	Birleştirilmiş
DL:	Deep Learning (Derin Öğrenme)
DMAH:	Düşük Molekül Ağırlıklı Heparin
DNN:	Deep Neural Network (Derin Sinir Ağı)
DVM:	Destek Vektör Makinesi
DVT:	Derin Ven Trombozu
EHR:	Elektronik Sağlık Kayıtları
FDR:	Negatif Tahmin Oranı
FN:	Yanlış Negatifler
FNN:	Feedforward Neural Networks
FP:	Yanlış Pozitifler
GPU:	Graphics Processing Unit (Grafik İşlemci Ünitesi)
GRU:	Gated Recurrent Units
HBYS:	Hastane Bilgi Yönetim Sistemi
JPEG:	Joint Photographic Experts Group
LCL:	Lateral Kollateral Bağ
LSTM:	Long Short-Term Memory
MCL:	Medial Kollateral Bağ
ML:	Machine Learning (Makine Öğrenmesi)
MLP:	Multi-Layer Perceptron
MRG:	Manyetik Rezonans Görüntüleme
NSAİİ:	Non-steroidal Antiinflamatuvar İlaçlar
PCL:	Posterior Çapraz Bağ
PPV:	Pozitif Tahmin Değeri
ReLU:	Rectified Linear Unit (Düzeltilmiş Doğrusal Birim)

ResNet:	Residual Network
RNN:	Recurrent Neural Networks
ROC:	Receiver Operating Characteristic
SEN:	Duyarlılık
SPE:	Özgüllük
TANH:	Hiperbolik Tanjant
TN:	Dođru Negatifler
TP:	Dođru Pozitifler
TPK:	Tibia Plato Kırığı
TPU:	Tensor Processing Unit (Tensör İşlemci Ünitesi)
X-Ray:	Direkt Grafi
YSA:	Yapay Sinir Ađı
YZ:	Yapay Zeka

ŞEKİLLER

- Şekil 1:** Diz anatomisi. A: Önden B: Arkadan görünümü
- Şekil 2:** Proksimal tibial kemiğin görünümü
- Şekil 3:** Schatzker Sınıflandırması
- Şekil 4:** AO/OTA Sınıflandırması
- Şekil 5:** Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme Arasındaki İlişki
- Şekil 6:** Biyolojik sinir hücresinin yapısı
- Şekil 7:** Yapay sinir hücresinin yapısı
- Şekil 8:** Yapay Sinir Ağları
- Şekil 9:** Derin sinir ağı çalışma prensibi
- Şekil 10:** Evrişimli sinir ağı çalışma prensibi
- Şekil 11:** Konvolüsyon katmanının işleyişi
- Şekil 12:** Maksimum havuzlama katmanının çalışması
- Şekil 13:** Tam bağlantılı katmanın çalışması
- Şekil 14:** AlexNet mimarisi işleyişi
- Şekil 15:** ResNet18 mimarisi işleyiş
- Şekil 16:** ResNet50 mimarisi işleyişi
- Şekil 17:** ResNet101 mimarisi işleyişi
- Şekil 18:** MobileNet mimarisi işleyişi
- Şekil 19:** Önerilen görüntü aşamasında birleştirme temelli modelin genel çerçevesi
- Şekil 20:** Önerilen öznetelik aşamasında birleştirme temelli modelin genel çerçevesi
- Şekil 21:** Literatürde sık kullanılan istatistiksel ölçütler
- Şekil 22:** Performans metriklerinin karmaşıklık matrisi örneği üzerinde gösterimi
- Şekil 23:** Derin öğrenme mimarilerinin (a) doğrulama ve (b) test veri setleri için tibia plato kırığı tespit doğruluklarının (ACC) bar grafik gösterimleri
- Şekil 24:** Derin öğrenme mimarilerinin (a) doğrulama ve (b) test veri setleri için tibia plato kırığı tespit Hassasiyet (SEN) ve Negatif tahmin oranı (FDR) karşılaştırması
- Şekil 25:** ResNet18 mimarisinin (a),(c),(e) doğrulama ve (b), (d),(f) test veri setleri için tibia plato kırığı tespit karmaşıklık matrisleri
- Şekil 26:** ResNet18 mimarisinin (a),(c),(e) doğrulama ve (b),(d),(f) test veri setleri için tibia plato kırığı tespit ROC eğrileri
- Şekil 27:** Derin öğrenme mimarilerinin (a) eğitim ve (b) test veri setleri için tibia plato kırığı tespit doğruluklarının (ACC) bar grafik gösterimleri

Şekil 28: Derin öğrenme mimarilerinin (a) eğitim ve (b) test veri setleri için tibia plato kırığı tespit Hassasiyet (SEN) ve Negatif tahmin oranı (FDR) karşılaştırması

Şekil 29: ResNet18 mimarisinin (a),(c),(e) eğitim ve (b), (d),(f) test veri setleri için tibia plato kırığı tespiti karmaşıklık matrisleri



TABLÖLAR

Tablo 1: Schatzker Sınıflandırması

Tablo 2: AO/OTA Sınıflandırması

Tablo 3: AlexNet doğrulama ve test veri setleri için performans sonuçları

Tablo 4: ResNet18 doğrulama ve test veri setleri için performans sonuçları

Tablo 5: ResNet50 doğrulama ve test veri setleri için performans sonuçları

Tablo 6: ResNet101 doğrulama ve test veri setleri için performans sonuçları

Tablo 7: MobileNet doğrulama ve test veri setleri için performans sonuçları

Tablo 8: AlexNet eğitim ve test veri setleri için performans sonuçları

Tablo 9: ResNet18 eğitim ve test veri setleri için performans sonuçları

Tablo 10: ResNet50 eğitim ve test veri setleri için performans sonuçları

Tablo 11: ResNet101 eğitim ve test veri setleri için performans sonuçları

Tablo 12: MobileNet eğitim ve test veri setleri için performans sonuçları

1. GİRİŞ

Tibia plato kırıkları, diz eklemine stabilitesi ve yük taşıma işlevinde kritik rol oynayan proksimal tibianın eklem yüzeyini etkileyen travmatik yaralanmalar olarak tanımlanır. Yüksek enerjili travmalar, motorlu araç kazaları ve düşme gibi mekanizmalar sonucu gelişen bu kırıklar, multidisipliner yaklaşımla tedavi edilmesi gereken karmaşık bir klinik tablo sunar. Hem intraartiküler hem de periartiküler yapıları etkileyen kırıklar, hem kemiğin iyileşme sürecini hem de eklem hareket açıklığını tehdit eder. Bu nedenle, tanı ve tedavi sürecinin dikkatlice planlanması, komplikasyon riskinin minimize edilmesi açısından önemlidir (1).

Geleneksel tanı yöntemleri, tibia plato kırıklarını görüntüleme ve sınıflandırmada temel teşkil etse de, karmaşık kırık desenlerinin yorumlanması bazı sınırlamalar içerebilir. Özellikle eklem yüzeyinin birden fazla bölgesinin etkilenmesi ve kırık parçalarının pozisyonunun doğru değerlendirilmesi gerektiğinde, görüntüleme sonuçlarının yorumlanmasında çeşitli zorluklarla karşılaşılabilir (2). Konvansiyonel radyografi, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi ileri görüntüleme teknikleri, kırıkların değerlendirilmesinde yaygın olarak kullanılır, ancak bu yöntemlerin yorumlanmasında gözlemciye bağlı değişkenlikler meydana gelebilir.

Yapay zeka ve makine öğrenmesi, tıp alanında giderek artan bir kullanım alanına sahiptir ve kırıkların tanı ve tedavi sürecinde de potansiyel olarak devrim niteliğinde katkılar sunmaktadır (3). Yazılım algoritmalarının geliştirilmesi ve klinik uygulamalara entegrasyonu ile kırık tanısında yüksek doğruluk oranları elde edilmesi amaçlanmaktadır. Tibia plato kırıklarının yorumlanmasında algoritmik çözümler, hem hız hem de doğruluk açısından gözlemciye bağımlılığı azaltarak tanı sürecini iyileştirmeyi vaat etmektedir. Bu tür algoritmaların kullanımında otomatik analiz ve karar destek sistemleri devreye girmekte, böylece klinik karar verme süreçlerinde daha nesnel sonuçlar elde edilmektedir.

Algoritma destekli görüntüleme analizleri, sadece kırık sınıflandırmasını iyileştirmekle kalmayıp, aynı zamanda cerrahi planlamayı da optimize etme potansiyeline sahiptir (4). Algoritmik yorumlamalar, kırık tipini ve lokalizasyonunu belirlemede daha detaylı bilgi sunarak optimal tedavi seçeneğinin belirlenmesine katkı sağlar. Tibia plato kırıklarında uygulanacak tedavi, kırığın tipi, yerleşimi, çevre yumuşak doku yaralanmalarının varlığı ve hasta özelliklerine göre değişkenlik göstermektedir. Bu değişkenlerin doğru değerlendirilmesi, tedavi başarısını doğrudan etkilemektedir.

Son yıllarda yapılan alıřmalar, kırık sınıflandırmalarında yazılım destekli analizlerin etkinliğini ortaya koymaktadır. Yapay zeka ve algoritmaların tibia plato kırıklarında başarılı sonuçlar verdiği ve gözlemciye bağımlılığı azaltarak tanı doğruluğunu artırdığı gözlenmiştir (5). Ancak, bu teknolojilerin klinik uygulamalara entegre edilmesinde bazı zorluklar da söz konusudur. Özellikle algoritma tabanlı sınıflandırma sistemlerinin güvenilirliğinin artırılması ve farklı hasta gruplarında geçerliliğinin kanıtlanması gerekmektedir.

Klinik pratiğe entegrasyonun kolaylaştırılması için yazılım algoritmalarının güvenilir, hızlı ve klinik olarak uygun sonuçlar verecek şekilde optimize edilmesi önemlidir. Özellikle acil tıp uzmanlarının, travmatik kırıkların tanısında ve yönetiminde algoritma destekli sistemleri kullanarak daha etkin bir yaklaşım sergilemesi beklenmektedir. Bu bağlamda, tibia plato kırıklarının algoritmik yorumlanmasının potansiyel avantajları, tanı sürecinin etkinliğini ve doğruluğunu artırarak hasta yönetimini iyileştirme fırsatı sunmaktadır.

Bilişim teknolojilerinin ve yapay zekanın tıbbi görüntülemelerde kullanımı ile tibia plato kırıkları gibi karmaşık kırıkların daha etkin bir şekilde yorumlanması sağlanabilir. Bu süreç, acil tıp uzmanlarının, tanı doğruluğunu artırmalarına ve tedavi planlamasında daha hızlı kararlar almalarına olanak tanıyarak hasta sonuçlarını iyileştirme potansiyeline sahiptir.


2. GENEL BİLGİLER

2.1. Diz Anatomisi

Diz eklemi, insan vücudunun en geniş sinovyal eklemi olup yük taşıma ve hareket fonksiyonlarının koordinasyonunu sağlayan karmaşık bir yapıdır. Bu eklem, femur, tibia ve patella kemiklerinin bir araya gelmesiyle oluşur ve kemiklerin yüzeylerini kaplayan hyalin kıkırdak, eklem hareketleri sırasında sürtünmeyi minimal seviyeye indirir. Diz eklemının yapı taşları olan kemikler, ligamentler, menisküs ve eklem kapsülü, statik ve dinamik stabilitenin korunmasında kritik bir rol oynar (Şekil 1). Femur ve tibia arasındaki eklem yüzeylerinin geniş temas alanı, yük dağılımını ve hareket genişliğini optimize ederek eklem dayanıklılığını artırır.

Menisküsler, diz ekleminde şok absorpsiyonu sağlayan fibro-kartilajinöz yapılardır ve medial ile lateral olmak üzere iki adet bulunur. Menisküs dokuları, yük taşıma, eklem stabilitesini destekleme ve kayganlık sağlama işlevleriyle dizin biyomekanik özelliklerine katkıda bulunur. Ani rotasyonel kuvvetler veya travmalar sonucu menisküslerde yırtık oluşması, dizin mekanik işlevlerinde aksamaya yol açabilir ve uzun vadede dejeneratif artrit riskini artırabilir. Bu yapılar ayrıca sinovyal sıvının homojen dağılımına katkıda bulunarak eklem sağlığını korur.

Dizin stabilitesinden sorumlu olan ligamentöz yapı, dört ana ligamentten oluşur: anterior çapraz bağ (ACL), posterior çapraz bağ (PCL), medial kollateral bağ (MCL) ve lateral kollateral bağ (LCL). Anterior ve posterior çapraz bağlar, dizin anteroposterior stabilitesini sağlarken, kollateral bağlar dizin varus ve valgus kuvvetlerine karşı direnç gösterir. ACL ve PCL gibi çapraz bağlar, özellikle rotasyonel ve translasyonel kuvvetlere karşı dizin stabilitesini sağlar (6). Ligamentlerde oluşan travmalar, diz eklemінде instabiliteye yol açarak, ileri düzeyde mobilite kaybı ve ağrı gibi semptomlara neden olabilir. Bu yapılar arasındaki etkileşim, dizin biyomekanik özelliklerini doğrudan etkileyen kritik bir faktördür.



Şekil 1: Diz anatomisi. A: Önden B: Arkadan görünümü

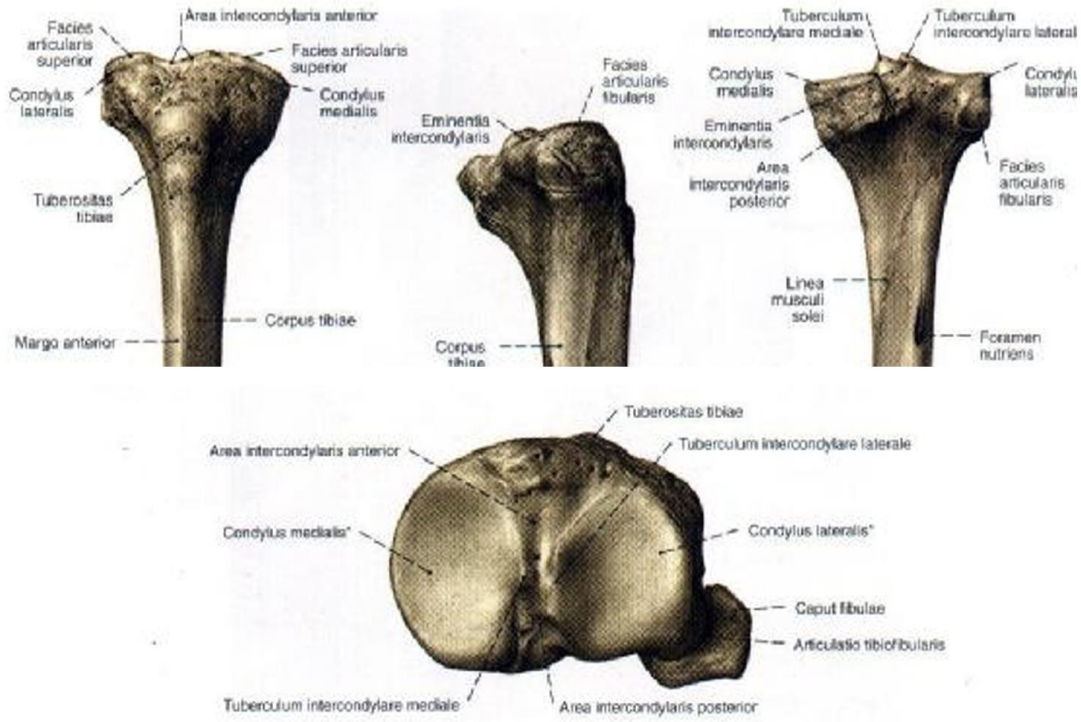
2.2. Tibia Plato Anatomisi

2.2.1. Tibia Plato Kemik Anatomisi

Tibia plato, tibia kemiğinin proksimal ucunda yer alan ve diz eklemi ile doğrudan ilişkili olan eklem yüzeyidir. Tibianın en üst kısmında bulunan bu yapı, medial (iç) ve lateral (dış) olmak üzere iki ayrı kondilden oluşur (Şekil 2). Medial tibia platosu, daha geniş ve daha kalın bir kemik yapısına sahip olup, vücut ağırlığının büyük bir kısmını taşır. Lateral tibia platosu ise nispeten daha ince ve düz bir yapıya sahiptir, ancak diz eklemi hareketlerinde önemli bir rol oynar (7). Tibia platosu, eklem yüzeyini kaplayan eklem kıkırdağı (hyalin kıkırdak) ile kaplıdır. Bu kıkırdak doku, femurun kondilleri ile uyumlu bir yüzey oluşturarak eklem hareketlerinin düzgün ve sürtünmesiz gerçekleşmesini sağlar. Tibia platosunun hemen altında, subkondral kemik yer alır ve bu yapı, eklem yüzeyine destek sağlayarak yük dağılımını düzenler.

Tibia platosu, çeşitli kırıklara yatkın bir anatomik bölgedir. Özellikle yüksek enerjili travmalar, tibia platosunda parçalı kırıklara, çökmelere ve eklem yüzeyinde düzensizliklere neden olabilir. Kemik yapısının yoğunluğuna bağlı olarak, medial tibia platosu daha dirençliken, lateral tibia platosu daha kırılabilir yapıdadır ve yüksek enerjili

yüklenmelere karşı daha hassastır. Tibia platosunun kemik anatomisi, diz ekleminin stabilitesi ve yük taşıma kapasitesi açısından kritik öneme sahiptir.



Şekil 2: Proksimal tibial kemiğin görünümü

2.2.2. Tibia Plato Ligamentöz Anatomisi

Tibia platosu, diz ekleminin stabilitesini sağlayan birçok ligamentöz yapı ile ilişkilidir. Bu ligamentler, eklem stabilitesini koruyarak tibia ve femurun uyumlu bir şekilde çalışmasını sağlar. Diz eklemi stabilize eden dört ana bağdan ikisi doğrudan tibia platosuna yapışır: **ön çapraz bağ (anterior cruciate ligament - ACL)** ve **arka çapraz bağ (posterior cruciate ligament - PCL)**. Ön çapraz bağ, tibia platosunun ön kısmına tutunarak femurun öne doğru kaymasını engeller ve dizin rotasyonel stabilitesini sağlar. Arka çapraz bağ ise tibianın arka kısmına bağlanarak femurun arkaya doğru yer değiştirmesini önler (8). Bu iki yapı, özellikle tibia plato kırıkları ile birlikte yaralanabilen kritik stabilizatörlerdir.

Tibia dizin dış stabilitesini destekler (9). Tibia platosu, menisküsler ile de doğrudan platosu ayrıca **medial kollateral bağ (MCL)** ve **lateral kollateral bağ (LCL)** ile de desteklenir. Medial kollateral bağ, tibia platosunun medial kısmına tutunarak dizin iç stabilitesini sağlar. Lateral kollateral bağ ise fibula başına bağlanarak ilişkilidir. **Medial ve lateral menisküsler**, tibia platosunun eklem yüzeyini koruyarak yük dağılımını

düzenler ve femurun kondilleri ile uyumlu bir yüzey oluşturur. Özellikle tibia plato kırıkları, menisküs yırtıkları ve bağ yaralanmaları ile birlikte görülebilir ve bu durum, eklem stabilitesinde bozulmalara yol açabilir.

Tibia platosu ile ilişkili ligamentöz yapıların sağlamlığı, diz eklemine bütünlüğü açısından kritik öneme sahiptir. Tibia plato kırıkları sırasında, bu bağların yaralanması eklem stabilitesinin bozulmasına, diz instabilitesine ve uzun vadede osteoartrit gibi dejeneratif değişikliklere neden olabilir. Bu nedenle, tibia plato kırıkları değerlendirilirken ligamentöz yapılar da dikkatlice incelenmeli ve gerektiğinde cerrahi veya konservatif tedavi ile stabilize sağlanmalıdır.

2.2.3. Tibia Plato Anatomisinin Klinik Önemi

Tibia plato, diz eklemine stabilitesini sağlayan ve yük taşıma kapasitesini belirleyen kritik bir yapıdır. Femurun tibia üzerinde dengeli hareket etmesine olanak tanıyan bu yapı, **medial ve lateral menisküsler ile anterior ve posterior cruciate ligamanlar** gibi eklem bileşenleriyle etkileşim halindedir. Eklem yüzeyini kaplayan kırık dokusu, femurun tibia üzerinde kaymasını sağlayarak sürtünmeyi azaltır.

Vücut ağırlığının büyük bir kısmı tibia plato tarafından taşınır ve yük iletiminde femur ile koordineli çalışır. Kırıklar veya travmalar, hem kemik yapısını hem de eklem yüzeyini etkileyerek dizin hareket kabiliyetini kısıtlayabilir (10). Tedavi sürecinde eklem yüzeyinin anatomik olarak düzeltilmesi büyük önem taşır; aksi takdirde, yanlış kaynama veya eklem dengesizliği osteoartrit gibi kalıcı problemlere yol açabilir.

2.3. Tibia Plato Kırıkları

2.3.1. Tibia Plato Kırıkları Tanımı

Tibia plato kırıkları, tibia'nın üst kısmında yer alan eklem yüzeylerinde meydana gelen kırıklardır ve genellikle diz eklemi ile doğrudan ilişkilidir. Tibia plato, femur ile birleşerek diz eklemine yük taşıyan yüzeyini oluşturur. Bu nedenle tibia plato kırıkları, sadece kemik bütünlüğünü değil, aynı zamanda diz eklemi fonksiyonunu da ciddi şekilde etkileyebilir (11). Bu tür kırıklar, genellikle yüksek enerjili travmalar sonucu oluşur. Trafik kazaları, yükseklikten düşmeler veya şiddetli spor yaralanmaları, tibia plato kırıklarının en yaygın nedenlerindedir. Kırıklar, çeşitli derecelerde olabilir; bazı vakalarda sadece eklem yüzeyi hafifçe hasar görürken, daha ciddi vakalarda eklem stabilitesi bozulabilir ve dizde ciddi deformasyonlar ortaya çıkabilir. Bu kırıklar, diz

eklemi üzerinde fonksiyonel bozulmalara yol açarak, hastanın yaşam kalitesini ciddi şekilde etkileyebilir.

2.3.2. Tibia Plato Kırıkları Sınıflandırmaları

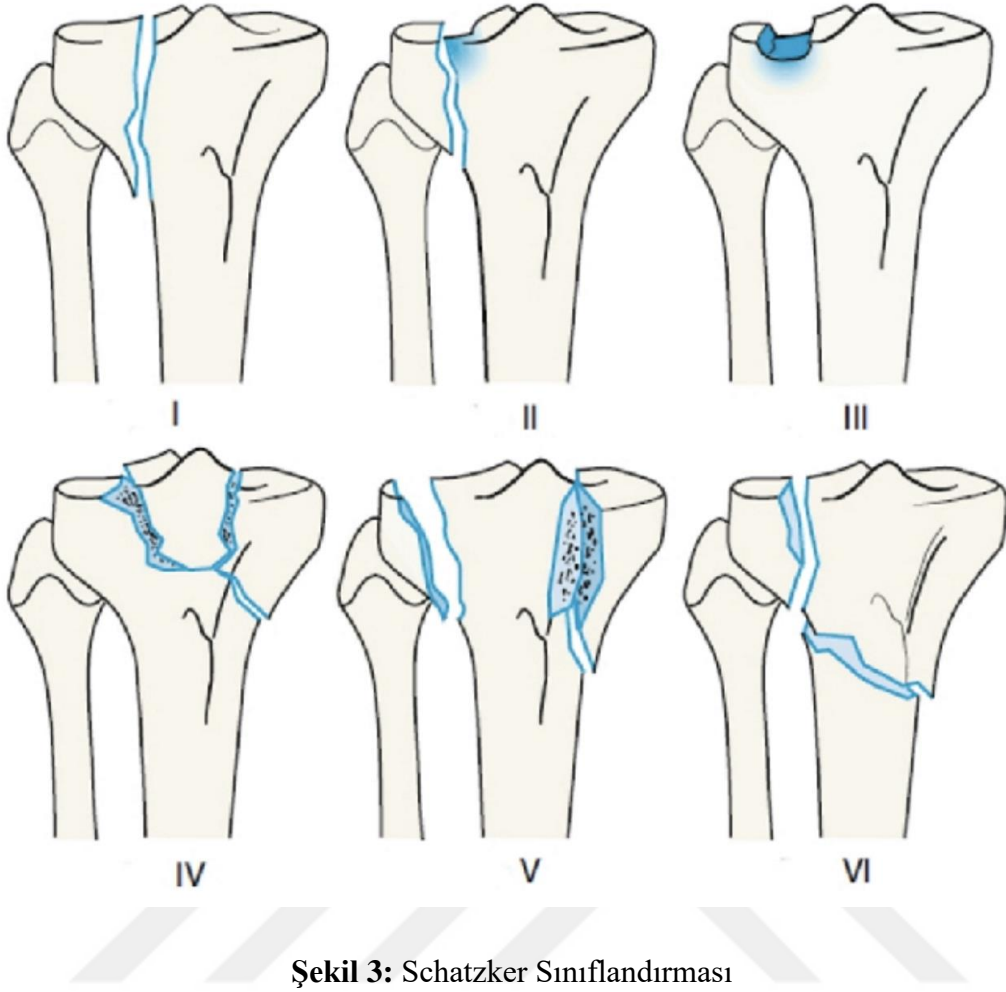
Schatzker Sınıflandırması

Schatzker sınıflaması, tibia plato kırıklarını morfolojik özelliklerine göre altı ana gruba ayıran en yaygın kullanılan sistemdir (Şekil 3) (12). Bu sınıflama, lateral plato kırıklarını daha sık içermesine rağmen, medial plato ve bikondiler kırıkları da kapsamaktadır.

Schatzker sınıflaması, klinik pratiğe en uygun ve yaygın kullanılan sistemlerden biri olup, cerrahi planlamada önemli bir rehberdir.

Tablo 1: Schatzker Sınıflandırması

Schatzker Tipi	Tanım	Özellikler	Klinik Önemi
Tip 1	Lateral plato ayrılma kırığı	Eklem yüzeyinde depresyon yoktur. Genellikle genç hastalarda düşük enerjili travmalar sonucu oluşur.	Stabil kırık olup konservatif veya minimal invaziv cerrahi ile tedavi edilebilir.
Tip 2	Lateral plato ayrılma + depresyon kırığı	Hem eklem yüzeyinde çökme hem de parçalı kırık içerir. Orta derecede instabiliteye neden olabilir.	Eklem rekonstrüksiyonu gerektirebilir, cerrahi müdahale sıklıkla uygulanır.
Tip 3	Lateral plato saf depresyon kırığı	Eklem yüzeyinde çökme vardır, ancak ayrılma görülmez.	Eklem yüzeyinin restorasyonu gereklidir. Tedavi sıklıkla cerrahidir.
Tip 4	Medial plato kırığı	Medial tibia platonusu içerir. Genellikle yüksek enerjili travmalar sonucu oluşur.	Medial plato kırıkları daha nadir görülür ancak instabiliteye yol açabilir. Cerrahi gerekebilir.
Tip 5	Bikondiler kırık	Hem medial hem de lateral tibia platonusu içerir. Genellikle eklem stabilitesi ciddi şekilde bozulur.	Yüksek enerjili travmalarda görülür. Plak ve vida ile eklem rekonstrüksiyonu gerekir.
Tip 6	Metafiz-diafiz ayrışmalı kırık	Tibia platosu kırığına diafiz ayrışması eşlik eder. Parçalı kırıklar görülebilir.	Yüksek enerjili travmaların neden olduğu kompleks kırıklardır. Multidisipliner cerrahi yaklaşım gerektirir.



Şekil 3: Schatzker Sınıflandırması

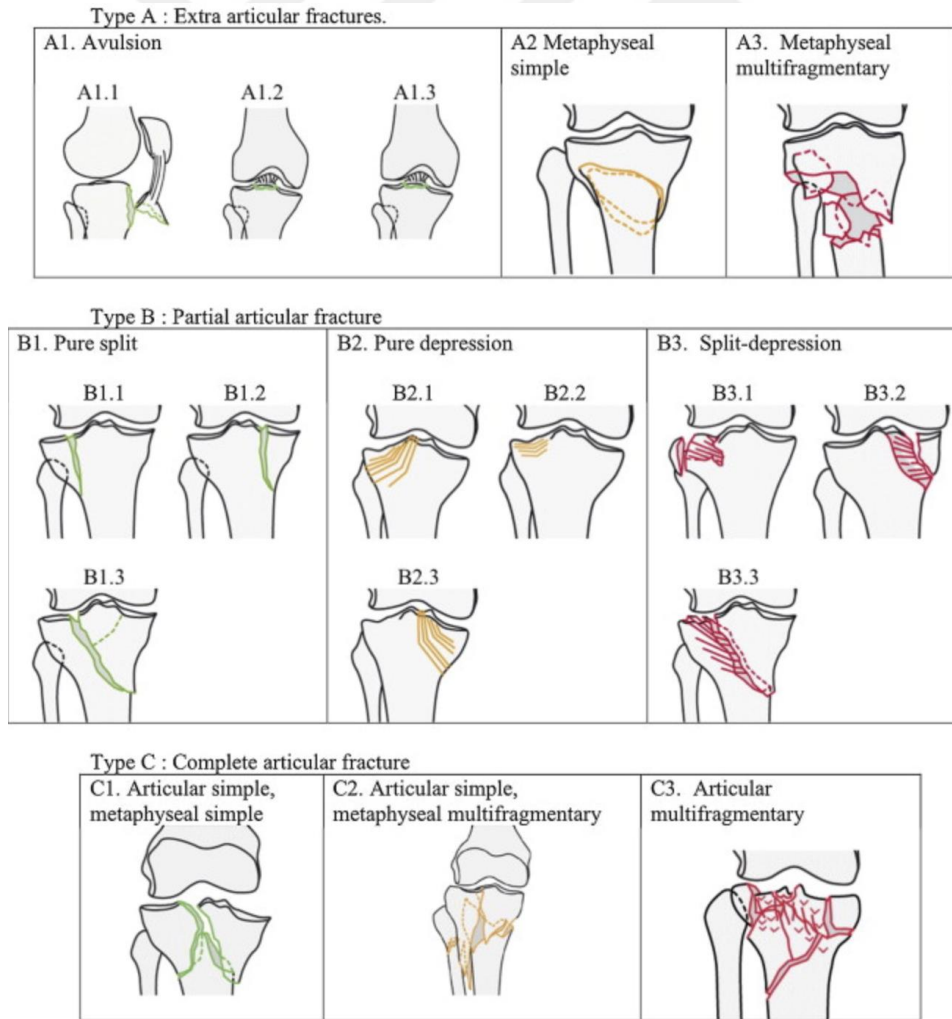
AO/OTA Sınıflandırması

AO/OTA (Arbeitsgemeinschaft für Osteosynthesefragen/Orthopaedic Trauma Association) sınıflaması, kırıkları daha ayrıntılı ve sistematik bir şekilde değerlendiren bir sınıflama sistemidir. Bu sistem, tibia plato kırıklarını ana başlıklar altında üç gruba ayırır (Şekil 4) (13).

AO/OTA sınıflaması, tibia plato kırıklarını daha detaylı bir şekilde alt gruplara ayırarak, tedavi yaklaşımını belirlemede daha geniş bir perspektif sunar.

Tablo 2: AO/OTA Sınıflandırması

Ana Kategori	Alt Kategori	Tanım
41-A (Ekstraartiküler – Eklem Dışı Kırıklar)	A1	Basit metafiz kırıkları (spiral, oblik veya transversal)
	A2	Metafiz diafiz ayrışmalı kırıklar
	A3	Multifragmenter metafiz kırıkları
41-B (Parsiyel Artiküler Kırıklar)	B1	Split (bölünmüş) kırıklar
	B2	Saf depresyon kırıkları
	B3	Split-depresyon kırıkları
41-C (Komple Artiküler Kırıklar)	C1	Basit metafiz ve basit eklem içi kırıklar
	C2	Multifragmenter metafiz ve basit eklem içi kırıklar
	C3	Multifragmenter metafiz ve eklem içi kırıklar



Şekil 4: AO/OTA Sınıflandırması

2.3.3. Tibia Plato Kırıkları Tanı ve Görüntüleme

Tibia plato kırıkları, acil serviste sık karşılaşılan ve erken tanı konulması gereken önemli ortopedik yaralanmalar arasındadır. Bu kırıklar genellikle yüksek enerjili travmalar (örneğin trafik kazaları, yüksekten düşmeler) veya yaşlı hastalarda düşük enerjili travmalar sonucu meydana gelir. Hastalar genellikle diz bölgesinde şiddetli ağrı, şişlik, eklem hareketlerinde kısıtlılık ve yük verme güclüğü ile başvururlar. Eklem içi hemartroz, ciltte ekimoz ve belirgin yumuşak doku hasarı, kırığın şiddeti hakkında önemli ipuçları sağlar. Açık kırıklar veya vasküler yaralanma bulguları (soğukluk, nabız alınamaması, kapiller dolum süresinde uzama) acil cerrahi müdahale gerektiren durumlar arasındadır.

Tibia plato kırıklarının tanısında **radyolojik görüntüleme yöntemleri** temel teşhis araçlarıdır. Acil serviste ilk basamak görüntüleme genellikle **direkt grafilerle** (ön-arka ve lateral diz grafileri) yapılır. Bu görüntüleme, eklem hattındaki düzensizlikleri, kırık hatlarını ve tibia platosunda meydana gelen depresyonu değerlendirmek için kullanılır. Bununla birlikte, özellikle minimal deplasmanlı kırıklar direkt grafilerde gözden kaçabilir. Bu nedenle, şüpheli vakalarda daha ileri görüntüleme yöntemleri gereklidir (14).

Tibia plato kırıklarının detaylı değerlendirilmesi için **bilgisayarlı tomografi (BT)** altın standart olarak kabul edilir. BT, eklem yüzeyindeki çökme miktarını, kırık parçalarının yer değiştirme derecesini ve eşlik eden metafizyal veya diafizyal kırıkları net bir şekilde gösterir. **Üç boyutlu rekonstrüksiyonlu BT**, cerrahi planlamada kritik önem taşır ve özellikle parçalı kırıkların detaylı analizini sağlar (15). Manyetik rezonans görüntüleme (**MRG**) ise özellikle eşlik eden yumuşak doku yaralanmalarını, özellikle ön çapraz bağ (ACL), menisküs ve kollateral bağ yaralanmalarını değerlendirmek için kullanılır (16). Ancak MRG, acil servis şartlarında genellikle ilk tercih edilen bir görüntüleme yöntemi değildir ve daha çok ileri değerlendirme aşamasında tercih edilir.

Acil serviste tibia plato kırığı tanısı konulduğunda, ilk yaklaşım hastanın **stabilizasyonu, ağrı kontrolü ve immobilizasyonudur**. Etkilenen ekstremitte atel veya uzun bacak splinti ile hareketsiz hale getirilerek, kırık uçlarının daha fazla yer değiştirmesi önlenir. Yumuşak doku ödeminin ilerlemesini önlemek için soğuk uygulama ve elevasyon önerilir (17). Kompartman sendromu açısından hastalar yakından izlenmeli, şiddetli ağrı, pasif germe ağrısı veya nörovasküler bozukluklar gelişirse acil cerrahi

dekompresyon (fasyotomi) düşünölmelidir. Uygun görüntöleme ve klinik değeriendirme sonucunda ortopedi veya travma cerrahisi ile multidisipliner bir yaklaşım benimsenerek tedavi planlanmalıdır.

2.3.4. Tibia Plato Kırıkları Tedavi

Tibia plato kırıklarının tedavisi, kırığın tipi, eklem stabilitesi, yumuşak doku yaralanmaları ve hastanın genel sağlık durumu gibi faktörlere bağılı olarak **medikal (konservatif) ve cerrahi** olmak üzere iki ana gruba ayrılır. Uygun tedavi yönteminin belirlenmesinde **Schatzker ve AO/OTA sınıflamaları**, kırık stabilitesi ve eklem yüzeyinde meydana gelen hasarın derecesi dikkate alınır.

2.3.4.1. Medikal (Konservatif) Tedavi

Konservatif tedavi, özellikle deplase olmamış veya minimal deplasmanlı tibia plato kırıklarında tercih edilir. Tip 1, Tip 2 ve Tip 3 Schatzker kırıklarında, eğer eklem yüzeyinde belirgin instabilite yoksa, **immobilizasyon ve fonksiyonel rehabilitasyon** ön plandadır (18). Tedavi sürecinde:

- **İmmobilizasyon:** İlk aşamada uzun bacak alçısı veya diz breysi kullanılarak kırık sahası korunur. Genellikle **4-6 hafta** yük vermeme prensibi uygulanır.
- **Ağrı kontrolü ve antiinflamatuvar tedavi:** Non-steroidal antiinflamatuvar ilaçlar (NSAİİ) ve analjezikler kullanılarak hastanın ağrısı kontrol altına alınır.
- **Tromboprofilaksi:** Uzun süreli immobilizasyon gerektiren hastalarda derin ven trombozu (DVT) riski arttığından düşük molekül ağırlıklı heparin (DMAH) veya oral antikoagülanlar ile pıhtı oluşumu önlenmelidir.
- **Fizik tedavi ve rehabilitasyon:** Erken dönemde diz hareket açıklığını korumaya yönelik egzersizler başlanmalı, yük verme süreci **6-8 hafta sonra** aşamalı olarak ilerletilmelidir.

Konservatif tedavi, eklem yüzeyinde depresyon veya instabilite gelişmeyen hastalarda başarılı sonuçlar verebilir. Ancak, takip sürecinde deformite veya osteoartrit gelişimi açısından hastalar yakın izlenmelidir.

2.3.4.1. Cerrahi Tedavi

Tibia plato kırıklarında cerrahi tedavi, eklem yüzeyinde belirgin deplasman (≥ 2 mm), instabilite, bikondiler kırıklar ve eşlik eden ligamentöz yaralanmalar varlığında gereklidir. Yüksek enerjili travmalara bağlı gelişen **Tip 4, Tip 5 ve Tip 6 Schatzker kırıkları**, genellikle cerrahi müdahale gerektiren kompleks kırıklardır (19). Cerrahi tedavi seçenekleri şunlardır:

- **Açık redüksiyon ve internal fiksasyon (ARİF):** Plak-vida sistemleri veya vida ile sabitleme yöntemleri kullanılarak eklem yüzeyi anatomik olarak restore edilir. Özellikle bikondiler kırıklarda lateral ve medial plak kombinasyonu kullanılır (20).
- **Eksternal fiksasyon:** Şiddetli yumuşak doku hasarı, açık kırıklar veya kompartman sendromu riskinin yüksek olduğu durumlarda **geçici veya kalıcı eksternal fiksasyon** tercih edilir (21).
- **Artroskopik destekli fiksasyon:** Minimal invaziv cerrahi yaklaşım olarak artroskopi eşliğinde kırık redüksiyonu ve vida ile tespit yapılabilir. Özellikle depresyon tipi kırıklarda kullanılır (22).

Cerrahi sonrası rehabilitasyon süreci hastanın prognozunu belirleyen en önemli faktörlerden biridir. Ameliyat sonrası erken hareket açıklığı egzersizleri başlatılmalı, ancak yük verme **8-12 hafta** boyunca kademeli olarak uygulanmalıdır. Hastalar uzun vadede post-travmatik osteoartrit, eklem sertliği ve kas atrofisi açısından takip edilmelidir.

2.3.5. Tibia Plato Kırıklarında Tedavi Sonrası Prognoz

Tibia plato kırıklarının tedavi sonrası prognozu, birçok faktöre bağlı olarak değişkenlik gösterir. **Hastanın yaşı, cinsiyeti, kırık tipi, eşlik eden yumuşak doku yaralanmaları ve uygulanan tedavi yöntemi**, uzun dönem sonuçları belirleyen temel faktörlerdir (23). Genel olarak, eklem yüzeyinin anatomik olarak restore edilmesi ve stabil bir fiksasyon sağlanması durumunda fonksiyonel sonuçlar daha başarılıdır. Ancak, post-travmatik osteoartrit, eklem sertliği ve kas atrofisi gibi komplikasyonlar, hastaların yaşam kalitesini etkileyebilir.

2.3.5.1. Yaş Göre Prognoz

Yaş, tibia plato kırıklarında prognozu belirleyen önemli bir faktördür. Genç hastalarda kemik iyileşmesi hızlı olup, kas gücü korunduğundan rehabilitasyon süreci daha başarılıdır. Stabil kırıklarda konservatif tedavi bile iyi sonuçlar verebilir. Yaşlı hastalarda ise osteoporoz nedeniyle iyileşme süresi uzar, post-travmatik osteoartrit riski artar ve eklem yüzeyinde çökme daha belirgin hale gelir.

2.3.5.2. Cinsiyete Göre Prognoz

Cinsiyetin prognoz üzerindeki etkisi, özellikle kemik yoğunluğu ve kas gücü ile ilişkilidir. Kadın hastalarda, özellikle menopoz sonrası dönemde osteoporotik kemik yapısı nedeniyle kırık iyileşmesi daha uzun sürebilir ve cerrahi sonrası komplikasyon oranları erkeklere göre daha yüksek olabilir. Buna karşılık, erkek hastalarda, genellikle yüksek enerjili travmalara bağlı daha kompleks kırıklar görülür. Bu durum cerrahi müdahale gereksinimini artırırken, genç erkek hastalar genellikle daha güçlü kas yapısına sahip olduklarından rehabilitasyon sürecine daha iyi yanıt verebilirler. Ancak, her iki cinsiyette de uzun dönem sonuçları belirleyen temel faktör, kırığın anatomik olarak doğru bir şekilde tespit edilmesi ve erken mobilizasyonun sağlanmasıdır (24).

2.3.5.3. Kırık Tipine Göre Prognoz

Tibia plato kırıklarının prognozu, kırık tipine göre büyük farklılıklar gösterir. Schatzker Tip 1 ve Tip 2 kırıkları, minimal deplasman gösterdiğinden konservatif veya cerrahi tedavi sonrası fonksiyonel iyileşme oranları yüksektir. Ancak, Tip 4, Tip 5 ve Tip 6 kırıkları, eklem yüzeyinde ciddi hasara ve instabiliteye neden olduğundan prognoz daha kötüdür. Özellikle bikondiler kırıklar ve diafiz-metafiz ayrışmalı kırıklarda eklem içi kırıkta dejenerasyonu hızlanarak erken dönemde osteoartrite yol açabilir. Kompleks kırıklarda cerrahi stabilizasyon sağlanamazsa, uzun dönemde eklem hareket açıklığında kısıtlılık ve kronik ağrı gibi komplikasyonlar ortaya çıkabilir (25).

Sonuç olarak, tibia plato kırıklarının prognozu çok faktörlü bir değerlendirme gerektirir. Anatomik redüksiyonun sağlanması, erken mobilizasyonun başlatılması ve hastaya özel rehabilitasyon protokollerinin uygulanması, uzun dönem sonuçları iyileştiren en önemli faktörlerdir. Ancak, ileri yaş, kompleks kırık tipleri ve yetersiz rehabilitasyon, prognozu olumsuz etkileyen faktörler arasında yer alır. Bu nedenle, her hastanın bireysel özellikleri göz önünde bulundurularak multidisipliner bir yaklaşımla tedavi planı oluşturulmalıdır.

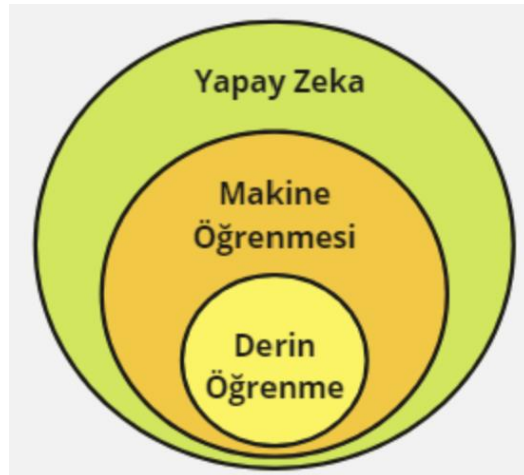
2.4. Yapay Zeka, Makine Öğrenme ve Derin Öğrenme

2.4.1. Yapay Zeka

Yapay zeka (YZ), bilgisayar sistemlerinin insan zekasına özgü bilişsel işlevleri simüle edebilme yeteneği olarak tanımlanır. Bu işlevler arasında problem çözme, öğrenme, muhakeme, dil işleme ve görsel algı yer alır. YZ, matematiksel modeller, istatistiksel yöntemler ve bilgisayar bilimleri ile desteklenen bir disiplin olup, günümüzde sağlık, mühendislik, finans ve lojistik gibi birçok alanda giderek artan bir şekilde kullanılmaktadır.

Sağlık alanında yapay zeka, veri analitiği ve tahminleme gücü sayesinde tanı, tedavi planlama ve hastalık yönetiminde devrim yaratma potansiyeline sahiptir. Görüntü analizi, klinik karar destek sistemleri, hasta takibi ve genetik araştırmalar gibi farklı alanlarda YZ uygulamaları etkin bir şekilde kullanılmaktadır. Özellikle tıbbi görüntüleme YZ, radyolojik verilerin hızlı ve doğru bir şekilde değerlendirilmesini sağlayarak tanı süreçlerini kolaylaştırmaktadır. Ayrıca, büyük veri setlerini analiz ederek klinik sonuçları tahmin etmek ve kişiselleştirilmiş tedavi planları oluşturmak için de güçlü bir araç sunmaktadır (26).

YZ'nin kullanımında en büyük avantajlardan biri, büyük miktarda karmaşık veriyi hızlı ve etkin bir şekilde analiz edebilme kapasitesidir. Ancak, YZ sistemlerinin uygulanmasında veri güvenliği, etik sorunlar ve modellerin doğruluğu gibi önemli zorluklar da bulunmaktadır. Sağlık alanında YZ'nin başarılı bir şekilde entegrasyonu, klinik süreçlerin iyileştirilmesine ve hasta sonuçlarının geliştirilmesine katkı sağlamakla birlikte, bu teknolojinin güvenli, şeffaf ve etik bir şekilde uygulanmasını gerektirir (27).



Şekil 5: Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme Arasındaki İlişki.

2.4.2. Makine Öğrenmesi

Makine öğrenmesi (ML), yapay zeka alanının bir alt dalı olup, bilgisayar sistemlerinin önceden programlanmaya gerek kalmadan verilerden öğrenme ve bu öğrenimi kullanarak tahminler veya kararlar alma yeteneği olarak tanımlanır (28). ML, istatistiksel modeller ve algoritmalar aracılığıyla örüntüleri tanıma ve anlamlı sonuçlar çıkarma üzerine odaklanır. Bu süreçte, sistemler ham veriyi analiz ederek zamanla performanslarını artırabilir. ML algoritmaları genellikle denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak sınıflandırılır.

Sağlık alanında makine öğrenmesi, tıbbi verilerin işlenmesi ve analizi konusunda çığır açan uygulamalara sahiptir. Elektronik sağlık kayıtlarından (EHR) hasta verilerinin analizi, tanı koyma süreçlerinin iyileştirilmesi ve tedavi sonuçlarının öngörülmesi gibi pek çok alanda kullanılmaktadır. Özellikle tıbbi görüntüleme alanında ML algoritmaları, radyolojik görüntülerin sınıflandırılması, patolojik bulguların tespiti ve hastalık evrelerinin belirlenmesinde yardımcıdır (29). Örneğin, ML tabanlı modeller, akciğer kanseri nodüllerini tespit etmek, kemik kırıklarını sınıflandırmak ve tümör boyutlarını analiz etmek için yaygın olarak kullanılmaktadır.

Makine öğrenmesi ayrıca acil tıp gibi dinamik ve hızlı kararların gerektiği alanlarda büyük bir potansiyele sahiptir. Hastaların vital bulguları, laboratuvar sonuçları ve diğer klinik verileri kullanılarak, sepsis, pulmoner tromboemboli veya pnömotoraks gibi hayati durumların erken tespiti mümkündür (30). Bununla birlikte, ML'nin etkinliği, kullanılan veri setlerinin kalitesi, çeşitliliği ve miktarı ile yakından ilişkilidir. Sağlık alanında makine öğrenmesi uygulamalarının yaygınlaşması, tıbbi karar süreçlerini destekleyerek hasta bakım kalitesini artırma potansiyeli taşımaktadır. Ancak, algoritmaların doğruluğu, etik kaygılar ve veri güvenliği konuları, bu teknolojinin başarılı bir şekilde entegrasyonu için dikkat edilmesi gereken önemli unsurlardır.

2.4.2.1. Denetimli Öğrenme

Denetimli öğrenme, etiketli verilerle eğitim yaparak modelin doğru sonuçlar üretmesini sağlamak için kullanılan bir makine öğrenmesi yöntemidir. Bu yöntemde, algoritma veriler üzerinde çalışırken doğru yanıtlar önceden belirlenmiş olur. Model, bu etiketli verilerden öğrenerek yeni verilere doğru tahminlerde bulunmayı öğrenir (31). Sağlık alanında, denetimli öğrenme genellikle hastaların klinik durumlarını veya

görüntüleme verilerini etiketleyerek, hastalıkların sınıflandırılması ve prognozunun yapılmasında kullanılır. Tibia plato kırıkları gibi durumlarda, radyolojik görüntüler etiketli verilerle beslenerek, algoritma kırık türlerini, şiddetini ve tedavi seçeneklerini doğru bir şekilde tahmin edebilir.

2.4.2.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, etiketli verilerin kullanılmadığı, yalnızca ham verilerin analiz edildiği bir yaklaşımdır. Bu yöntem, verilerdeki gizli yapıları ve ilişkileri keşfetmek için kullanılır (32). Örneğin, hastaların çeşitli klinik parametreleri arasındaki benzerlikleri veya grupları belirlemek için kullanılabilir. Tibia plato kırıklarının tedavisinde, denetimsiz öğrenme, farklı hasta gruplarının tedavi süreçlerini ve iyileşme sürelerini gruplandırarak, tedavi stratejilerinin daha iyi şekillendirilmesini sağlayabilir. Bu tür bir analiz, yeni alt grupların keşfi ve tedaviye dair daha derin bir anlayışa yol açabilir.

2.4.2.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, bir modelin çevresiyle etkileşime girerek ve ödüller veya cezalar alarak öğrenmesini sağlar. Bu yöntem, en iyi eylemi seçmeyi öğrenmek için kullanılır ve genellikle dinamik ve sürekli değişen ortamlarda uygulanır (33). Sağlık sektöründe, pekiştirmeli öğrenme, tedavi süreçlerini optimize etmek için kullanılabilir. Örneğin, bir hastanın iyileşme sürecinde, bir yapay zeka sistemi sürekli olarak tedavi yöntemlerini deneyebilir ve hangi müdahalenin en iyi sonucu verdiğini gözlemleyerek optimal tedavi protokollerini geliştirebilir. Tibia plato kırıkları gibi karmaşık vakalarda, pekiştirmeli öğrenme, farklı tedavi yaklaşımlarını test ederek, en uygun tedavi sürecini belirleyebilir.

2.4.2.4. Destek Vektör Makinesi (DVM) Sınıflandırıcı

Destek Vektör Makinesi (DVM), verileri en iyi şekilde ayıran bir **hiper düzlem** belirleyerek sınıflandırma yapan bir makine öğrenme algoritmasıdır (34). Tibia plato kırıkları gibi radyolojik görüntülerde, DVM kırık varlığını tespit etmek ve kırık tiplerini sınıflandırmak için kullanılabilir. **Çekirdek (kernel) fonksiyonları** sayesinde, doğrusal olarak ayrılamayan veriler daha yüksek boyutlu uzaylara dönüştürülerek analiz edilebilir.

DVM'nin en önemli avantajı, **yüksek boyutlu verilerle etkili çalışması ve aşırı öğrenmeye karşı dayanıklı olmasıdır**. Özellikle BT veya MRG gibi görüntüleme

yöntemlerinden elde edilen büyük veri setlerinde, kırık tespitinde başarılı sonuçlar verir (35). Doğru çekirdek fonksiyonu ve hiperparametre ayarları ile DVM, yapay zeka destekli klinik karar mekanizmalarına katkı sağlayabilir.

2.4.3. Yapay Sinir Ağı

2.4.3.1. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağları (YSA), insan beyninin çalışma prensiplerinden ilham alarak geliştirilmiş hesaplama modelleridir. Bu ağlar, çeşitli veri setlerinden öğrenme yaparak bir problemi çözme kapasitesine sahiptir (36). Temel olarak, çok katmanlı yapılarla birbirine bağlı "sinir hücreleri" olarak tanımlanabilir ve bu hücreler arasında aktarılan veriler, ağı öğrenme ve tahmin yapma yeteneğini sağlar. YSA'lar, girdi verilerini işleyerek çıktılar üretirken, doğruluk oranını artırmak amacıyla ağı bağlantılarını güçlendirir veya zayıflatır. Bu süreç, "ağırlık güncelleme" olarak adlandırılır ve genellikle geri yayılım algoritması (backpropagation) kullanılarak yapılır.

2.4.3.2. Yapay Sinir Ağlarının Kullanım Alanları


Yapay sinir ağları, özellikle büyük veri ve karmaşık problem çözme gerektiren alanlarda etkili sonuçlar ortaya koymaktadır. Sağlık sektöründe, bu ağlar görüntüleme verileri (örneğin, MRG veya BT taramaları) üzerinden hastalık tanıları koymak, tedavi süreçlerini izlemek ve medikal prognozları tahmin etmek için kullanılır. Ayrıca, genetik veri analizi, ilaç keşfi ve kişiselleştirilmiş tıp gibi alanlarda da önemli bir rol oynamaktadır. YSA'lar, biyomedikal mühendislikte proteomik analizlerden, robotik cerrahiden, hasta izleme sistemlerine kadar çok çeşitli uygulama alanlarına sahiptir (37).

2.4.3.3. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

Bir yapay sinir ağı, üç ana katmandan oluşur: giriş katmanı, gizli katmanlar ve çıkış katmanı. Giriş katmanı, dışarıdan gelen verileri alırken, gizli katmanlar bu verileri işler ve çıkış katmanı nihai tahmin veya sınıflandırma sonuçlarını üretir (38). Her katmanda yer alan "sinir hücreleri" (nöronlar), ağırlıklarla bağlanarak bir bilgi iletimi gerçekleştirir. Her hücre, aldığı girdi verilerini bir aktivasyon fonksiyonu kullanarak işler ve ardından çıktı üretir. Bu yapı, biyolojik sinir hücrelerinin (nöronların) bilgi işlemlerini taklit etmektedir, ancak burada kullanılan bağlantılar ve iletim süreçleri sayısal ve algoritmik bir temele dayanmaktadır.

2.4.3.3.1. Biyolojik Sinir Hücresi

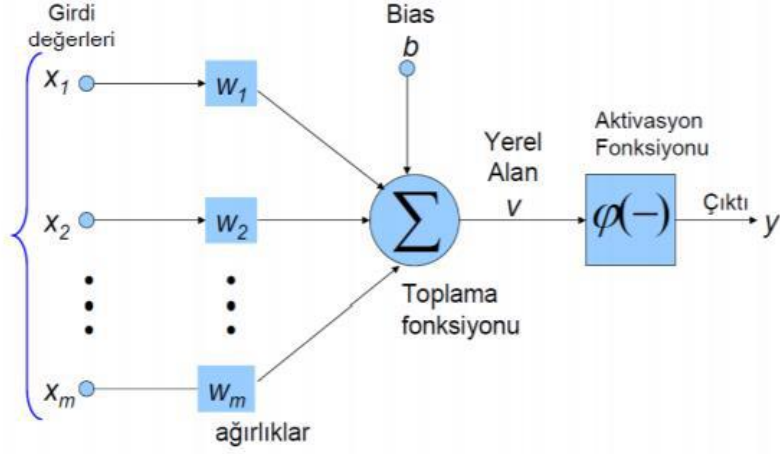
Biyolojik sinir hücreleri, vücutta elektriksel ve kimyasal sinyalleri iletmek için tasarlanmış hücrelerdir (Şekil 6). Bir nöron, dendritler aracılığıyla diğer hücrelerden sinyaller alır, bu sinyaller hücrenin gövdesinde işlenir ve ardından akson aracılığıyla diğer hücelere iletilir. Bu elektriksel sinyaller, sinapslarda kimyasal mesajlara dönüşür ve bu süreç, beynin bilgi işleme kapasitesinin temelini oluşturur. Biyolojik sinir hücreleri arasındaki bağlantılar, öğrenme ve hafızanın temel mekanizmalarını destekler. Yapay sinir ağları, bu biyolojik süreçleri taklit ederek veri analizi ve öğrenme gerçekleştirir.



Şekil 6: Biyolojik sinir hücresinin yapısı

2.4.3.3.2. Yapay Sinir Hücresi

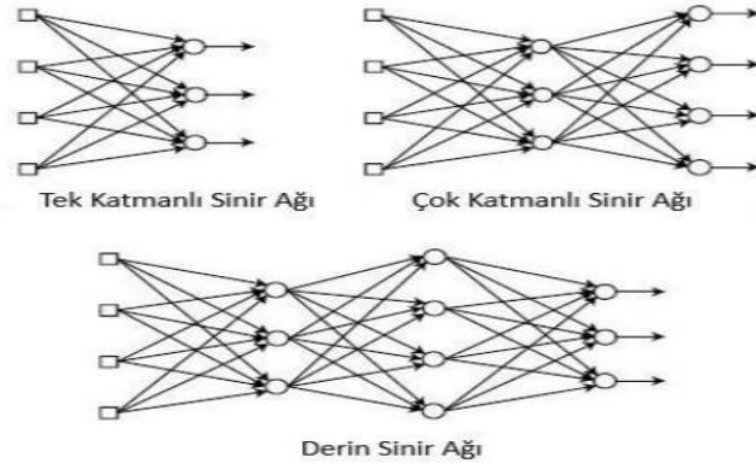
Yapay sinir hücreleri, biyolojik sinir hücrelerinin fonksiyonlarını taklit etmek için dijital ortamda oluşturulmuş model birimlerdir. Bu yapay hücreler, verilen girdi verilerini matematiksel işlemlerle işler ve çıktılar üretir. Girdi verileri, ağırlıklarla çarpılıp toplandıktan sonra, genellikle sigmoid, hiperbolik tanjant (tanh) veya ReLU gibi aktivasyon fonksiyonlarından geçirilir. Bu fonksiyonlar, verinin doğrusal olmayan bir şekilde işlenmesini sağlar, böylece daha karmaşık ilişkiler öğrenilebilir (38). Yapay sinir hücrelerinin doğru bir şekilde çalışabilmesi için eğitim sürecinde ağırlıklar optimize edilir (Şekil 7) (39).



Şekil 7: Yapay sinir hücresinin yapısı

2.4.3.4. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağları, yapıları ve öğrenme yöntemlerine göre çeşitli kategorilere ayrılabilir. En yaygın sınıflandırmalardan biri, ağın katman sayısına ve bağlantı şekline göre yapılan ayırmadır (Şekil 8). Tek katmanlı ağlar (örneğin, perceptron), basit sınıflandırma problemleri için kullanılırken, çok katmanlı ağlar (MLP - Multi-Layer Perceptron) daha karmaşık problemlerin çözümünde etkilidir. Derin öğrenme ağları ise, çok sayıda gizli katmana sahip olup, büyük veri setlerinden karmaşık örüntüleri tanımda başarılıdır (40).



Şekil 8: Yapay Sinir Ağları

2.4.3.4.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağları (Feedforward Neural Networks - FNN), verilerin yalnızca girişten çıkışa doğru ilerlediği, en basit ve en yaygın kullanılan yapay sinir ağı

modelidir (41). Bu ağılarda, giriş katmanındaki veriler sırasıyla gizli katmanlardan geçer ve nihayetinde çıkış katmanına ulaşır. İleri beslemeli yapılar, her bir katmandan çıkan verilerin bir sonraki katmana aktarılmasıyla çalışır ve geri dönme veya döngüsel bağlantılar bulunmaz. Bu ağılar, genellikle denetimli öğrenme yöntemleriyle eğitilir ve sınıflandırma veya regresyon gibi belirli görevleri yerine getirmek için kullanılır. Model, her eğitim adımında ağıın bağlantı ağırlıklarını optimize ederek, daha doğru çıktılar elde etmeyi hedefler.

2.4.3.4.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağları (Recurrent Neural Networks - RNN), ileri beslemeli yapıları aşan, zamanla değişen verileri işleyebilme yeteneğine sahip ağlardır. RNN'lerde, bir katmandan elde edilen çıktı, yalnızca bir sonraki katmana değil, aynı zamanda geri dönerek mevcut katmana da iletilir. Bu döngüsel bağlantılar sayesinde ağ, geçmişteki verileri hafızasında tutarak, zaman serileri, dil modelleme ve konuşma tanıma gibi uygulamalarda daha etkili sonuçlar elde eder (42). Geri besleme mekanizması, ağıın bir "hafıza"ya sahip olmasına olanak tanır ve zaman bağımlı verilerin analizini sağlar. Ancak, RNN'ler daha karmaşık yapılar olduğundan, uzun süreli bağımlılıkları öğrenmede zorluk yaşayabilirler; bu nedenle uzun vadeli hafıza gerektiren görevler için genellikle Gated Recurrent Units (GRU) veya Long Short-Term Memory (LSTM) gibi türevleri tercih edilir.

2.4.4. Derin Öğrenme

2.4.4.1. Tanım ve Tarihi

Derin öğrenme (DL), makine öğrenmesinin bir alt dalı olarak, çok katmanlı yapay sinir ağları kullanılarak verilerden otomatik olarak özellik çıkarımı ve öğrenim sağlayan bir yöntemdir. İnsan beyninin sinir ağlarını taklit eden bu algoritmalar, genellikle büyük ve karmaşık veri setleri üzerinde çalışarak yüksek doğruluk oranlarına ulaşır (40). Derin öğrenmenin temel özelliği, hiyerarşik bir yapı kullanarak verilerdeki soyut ve yüksek düzeydeki özellikleri otomatik olarak öğrenebilmesidir. Bu yöntem, görüntü işleme, ses tanıma, doğal dil işleme ve biyomedikal verilerin analizi gibi birçok alanda devrim yaratmıştır.

Derin öğrenmenin tarihi, 1940'larda McCulloch ve Pitts'in yapay nöron modelini tanımlamasıyla başlar. Daha sonra 1950'lerde ve 1960'larda Rosenblatt'ın "perceptron"

algoritması geliştirilmiş ve yapay sinir ağlarına olan ilgi artmıştır. Ancak, 1980'lere gelindiğinde bu algoritmaların sınırlı hesaplama gücü ve eksik veri setleri nedeniyle performanslarının düşük olduğu anlaşılmış ve araştırmalar duraklama dönemine girmiştir. 1986 yılında Rumelhart, Hinton ve Williams tarafından geri yayılım (backpropagation) algoritmasının tanıtılması, sinir ağlarının yeniden gündeme gelmesini sağlamıştır (43).

2000'li yıllarda, artan hesaplama gücü, büyük veri setlerinin erişilebilirliği ve grafik işlemcilerin (GPU) gelişimi, derin öğrenmenin yeniden yükselişine öncülük etmiştir. Özellikle 2012 yılında AlexNet'in, görüntü sınıflandırma yarışması olan ImageNet'teki başarısı, derin öğrenmenin dikkatleri üzerine çekmesine neden olmuştur. Günümüzde derin öğrenme, tıp dahil birçok alanda yaygın olarak kullanılan bir teknoloji haline gelmiş ve sağlık sektöründe tanı, prognoz ve tedavi süreçlerinde devrim niteliğinde katkılar sağlamaktadır.


2.4.4.2. Derin Sinir Ağı (Deep Neural Network, DNN)

Derin sinir ağı (Deep Neural Network, DNN), derin öğrenmenin temelini oluşturan ve çok katmanlı bir yapay sinir ağı mimarisine dayanan bir hesaplama modelidir. Bu ağlar, birbirine bağlı nöronlardan oluşan bir yapı şeklinde organize edilmiştir. Derin sinir ağlarında, veri giriş katmanından başlayarak bir dizi gizli katman aracılığıyla işlenir ve sonunda bir çıkış katmanına ulaşır (Şekil 9). Her bir gizli katman, bir önceki katmandan aldığı bilgiyi daha karmaşık ve soyut özelliklere dönüştürerek işler. Bu çok katmanlı yapı, derin sinir ağlarını geleneksel sinir ağlarından ayıran temel özelliktir (40).

DNN'lerin temel yapı taşları olan yapay nöronlar, biyolojik nöronlara benzer şekilde çalışır. Her nöron, kendisine gelen girişleri alır, bir ağırlık ve bias ile işler ve aktivasyon fonksiyonu yardımıyla çıkış verir. Aktivasyon fonksiyonları, özellikle doğrusal olmayan ilişkilerin öğrenilmesini sağlar ve ağın karmaşık problemleri çözme kapasitesini artırır (44). Derin sinir ağlarında kullanılan en yaygın aktivasyon fonksiyonları arasında ReLU (Rectified Linear Unit), sigmoid ve tanh yer alır. Bu ağlar, verilerdeki karmaşık ilişkileri öğrenmek ve doğrusal olmayan ayrımları modellemek için özel olarak tasarlanmıştır.

DNN'lerin sağlık alanındaki kullanımı, özellikle tıbbi görüntü analizi ve klinik karar destek sistemlerinde devrim niteliğinde ilerlemelere yol açmıştır. Evrişimli sinir ağları (CNN) gibi derin öğrenme türevleri, radyolojik görüntülerden patolojik bulguların tespit edilmesi veya sınıflandırılmasında yüksek başarı göstermektedir (45). Örneğin, akciğer kanseri nodüllerinin erken tespiti veya tibia kırıkları gibi ortopedik lezyonların sınıflandırılması gibi alanlarda DNN'ler sıkça kullanılmaktadır.

Bununla birlikte, derin sinir ağlarının etkin bir şekilde uygulanması için büyük miktarda kaliteli veriye ve yüksek hesaplama gücüne ihtiyaç duyulur. Ayrıca, DNN'lerin "kara kutu" yapısı nedeniyle karar süreçlerinin açıklanabilirliği sınırlıdır, bu da sağlık gibi kritik alanlarda güvenilirlik ve şeffaflık sorunlarını gündeme getirir. Tüm bu zorluklara rağmen, DNN'ler sağlık alanında yüksek doğruluk oranları ve kişiselleştirilmiş tedavi imkanları sunarak modern tıbbın önemli bir bileşeni haline gelmiştir (46).



Şekil 9: Derin sinir ağı çalışma prensibi


2.4.4.3. Evrişimli Sinir Ağı (Convolutional Neural Network, CNN)

Evrişimli sinir ağı (Convolutional Neural Network, CNN) özellikle görüntü işleme ve tanıma işlemleri için geliştirilmiş özel bir yapay sinir ağı yapısıdır. CNN'ler, geleneksel yapay sinir ağlarından farklı olarak, görüntülerdeki uzamsal bağlantılar ve desenleri öğrenmek için evrişim işlemlerini kullanır. Bunlar, özellikle büyük veri setlerinde otomatik özellik çıkarımı yaparak manuel özellik mühendisliğine olan

harcamaları azaltır (47). CNN'ler genellikle üç temel katmandan oluşur: evrişimsel katmanlar (görüntüdeki temel özellikleri belirler), havuzlama katmanları (veri kırıkları işlemleri ayırır) ve tam bağlantılı katmanlar (çıktıyı sınıflandırır) (Şekil 10) (48).

CNN'ler, tedavi, görüntü analizinde geniş bir kullanım alanına sahiptir. Radyolojik görüntülerden (MRG, BT, X-Ray) anormal dokuların değişiklikleri, histopatolojik görüntülerde kanserin sınıflandırılması ve oftalmoloji alanında diyabetik retinopati oluşum teşhisi gibi uygulamalarda yaygın olarak kullanılmaktadır (49). Evrişim katmanları, özellikle tıbbi görüntülerde belirli anatomik yapılar ve patolojiyi ayırt etmeye yardımcı olan, ağ derinleştikçe daha karmaşık ve soyut özellikleri de belirlemektedir.

CNN tabanlı modellerin başarısı, büyük miktarda etiketlenmiş veriye ve güçlü işlemcili sistemlere bağlıdır. Ancak, transfer öğrenme yöntemi (daha önce eğitilmiş bir derin öğrenme modelinin, farklı ancak benzer bir problem için yeniden kullanılması) sayesinde daha küçük veri setleriyle de başarılı sonuçlar alınabilir. Tıbbi alanda, CNN modellerinin nasıl karar verdiği tam olarak anlaşılamadığı için yorumlanabilirliği bazen sınırlıdır. Ancak, yapılan geliştirmeler ve özel dikkat mekanizmaları ile bu modellerin sağlık sektöründeki güvenilirliği ve performansı artırılmaktadır (50).




Şekil 10: Evrişimli sinir ağı çalışma prensibi

2.4.4.3.1. CNN Katman Türleri

Evrişimsel Katmanlar (Convolutional Layers)

Evrişimsel katmanlar, CNN mimarisinin temel yapı taşlarından biridir ve modelin görüntülerdeki önemli özellikleri öğrenmesini sağlar. Bu katman, giriş görüntüsündeki küçük bölgelerdeki desenleri algılamak için filtreler (kernels) kullanır. Her bir filtre, görüntü üzerinde kayarak (sliding) işlem yapar ve bu işlem sırasında, giriş


görüntüsündeki lokal özellikleri çıkarır. Evrişim katmanları, özellikle düşük seviyeli özellikleri, örneğin kenarları, köşeleri ve renk geçişlerini öğrenir (51). Bu süreç, ağın daha derin katmanlarında daha karmaşık ve soyut özelliklerin öğrenilmesine zemin hazırlar. Sonuç olarak, konvolüsyon katmanları, CNN'nin görsel verilerdeki desenleri anlamasını ve görüntüleri sınıflandırabilmesini sağlayan temel mekanizmalardır (Şekil 11) (52).



Şekil 11: Konvolüsyon katmanının işleyişi

Havuzlama Katmanları (Pooling Layers)

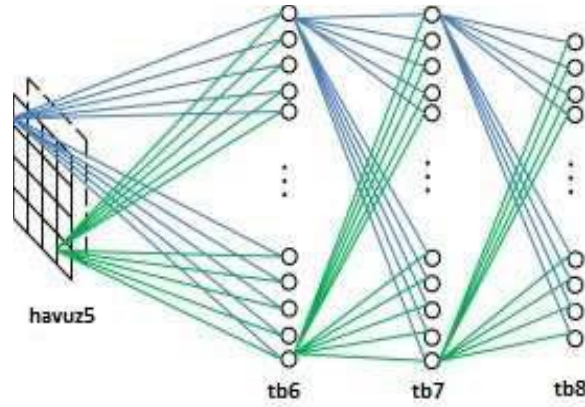
Havuzlama katmanları, CNN mimarisinde özellik haritalarının boyutunu küçültmek ve hesaplama maliyetini azaltmak için kullanılır. Bu katmanlar, belirli bir bölgedeki en yüksek veya ortalama değeri seçerek veri boyutunu azaltırken, önemli özelliklerin korunmasını sağlar. En yaygın kullanılan havuzlama yöntemi **maksimum havuzlama (max pooling)** olup, belirlenen filtre boyutundaki en yüksek piksel değerini seçerek özelliklerin daha belirgin hale gelmesini sağlar. **Ortalama havuzlama (average pooling)** ise bölgedeki ortalama değeri alarak daha yumuşak bir çıktı üretir (53). Havuzlama işlemi, modelin küçük kaymalara ve bozulmalara karşı daha dayanıklı hale gelmesine yardımcı olurken, aşırı öğrenme (overfitting) riskini de azaltır (Şekil 12) (52).



Şekil 12: Maksimum havuzlama katmanının çalışması

Tam Bağlantılı Katmanlar (Fully Connected Layers)

Tam bağlantılı katmanlar, CNN'nin son aşamasında yer alarak sınıflandırma işlemini gerçekleştiren katmanlardır. Bu katmanlarda, önceki evrişim ve havuzlama katmanlarından elde edilen özellikler bir vektör haline getirilir ve yapay sinir ağlarındaki klasik tam bağlantılı nöronlara iletilir. Her nöron, önceki katmandaki tüm nöronlarla bağlantılıdır ve belirli ağırlıklar aracılığıyla bilgiyi işler. Bu aşamada, genellikle **Aktivasyon Fonksiyonları (örneğin, ReLU veya Softmax)** kullanılarak modelin çıktıları sınıflandırma için optimize edilir (54). Tam bağlantılı katmanlar, modelin son karar mekanizmasını oluşturur ve belirlenen sınıflara ait olasılıkları hesaplar, böylece nihai tahmin yapılır (Şekil 13) (52).



Şekil 13: Tam bağlantılı katmanın çalışması

2.4.4.4. Derin Öğrenmede Sıklıkla Karşılaşılan Güçlükler

Derin öğrenme modellerinde en önemli zorluklardan biri aşırı öğrenme (overfitting) problemidir. Aşırı öğrenme, modelin eğitim verisine gereğinden fazla adapte olması sonucu ortaya çıkar ve modelin yeni, daha önce görmediği veriler üzerinde düşük performans göstermesine neden olur (55). Özellikle tıbbi veriler gibi sınırlı ve dengesiz veri setleri ile çalışırken, modelin gerçek dünyadaki genel geçer kalıpları öğrenmek yerine eğitim setindeki rastlantısal gürültüyü öğrenmesi mümkündür. Aşırı öğrenmenin önüne geçmek için veri artırma (data augmentation), erken durdurma (early stopping) ve dropout gibi düzenleme (regularization) teknikleri kullanılabilir.

Bir diğer önemli zorluk hesaplama yüküdür (computational cost). Derin öğrenme modelleri genellikle büyük miktarda veri ve çok sayıda parametre içerdiğinden, bu modellerin eğitimi yüksek hesaplama gücü gerektirir (56). Özellikle medikal görüntüleme gibi alanlarda, yüksek çözünürlüklü verilerin işlenmesi büyük zaman ve donanım gereksinimleri oluşturur. Yetersiz donanım kaynakları, modelin eğitim sürecini yavaşlatarak analizlerin gecikmesine yol açabilir. Bu sorunun üstesinden gelmek için GPU (Grafik İşlemci Ünitesi) ve TPU (Tensör İşlemci Ünitesi) gibi donanımların kullanımı önemlidir.

Derin öğrenmenin karşılaştığı bir diğer temel sorun ise kaybolan gradyan (vanishing gradient) problemidir. Ağ derinliği arttıkça, geri yayılım algoritması (backpropagation) sırasında hata sinyali, ilk katmanlara doğru yayılırken giderek küçülür. Bu durum, erken katmanlardaki ağırlıkların güncellenmesini zorlaştırır ve modelin öğrenme kapasitesini sınırlayarak performansın düşmesine neden olabilir. Kaybolan gradyan problemini önlemek için ReLU (Rectified Linear Unit) gibi aktivasyon fonksiyonları ve ResNet gibi rezidüel bağlantılar içeren mimariler kullanılarak daha derin ağların eğitimi kolaylaştırılabilir (57).


2.4.4.5. Literatürde Sık Kullanılan Derin Öğrenme Mimarileri

2.4.4.5.1 AlexNet

AlexNet, derin öğrenme alanında çığır açan bir evrimsel sinir ağı (Convolutional Neural Network, CNN) mimarisidir ve 2012 yılında ImageNet yarışmasındaki başarısıyla büyük bir etki yaratmıştır. Bu ağ, milyonlarca görüntüden oluşan veri setleri üzerinde eğitilerek nesne tanıma ve sınıflandırma problemlerinde olağanüstü bir performans göstermiştir. AlexNet'in temel yeniliği, çok katmanlı bir yapı kullanarak görüntülerden

özellik çıkarma kapasitesini artırması ve büyük veri setlerinde etkili bir şekilde çalışabilmesidir. Bu mimaride, birbirini takip eden evrişim katmanları (görüntülerdeki özellikleri öğrenmek için) ve max-pooling katmanları (gürültüyü azaltıp önemli özellikleri vurgulamak için) yer alır. Ayrıca, doğrusal olmayan ReLU aktivasyon fonksiyonu ile ağı daha hızlı ve etkili bir şekilde öğrenmesi sağlanır (58).

AlexNet'in bir diğer önemli özelliği, büyük miktarda veriyi işleyebilmek için grafik işlemcilerin (GPU) gücünden yararlanmasıdır. Bu durum, derin öğrenme modellerinin sağlık alanındaki uygulanabilirliğini artırmıştır. Örneğin, tıbbi görüntü analizi ve sınıflandırmasında AlexNet mimarisi, X-Ray, MRG ve BT gibi radyolojik görüntülerde anormal yapıları tespit etmek için kullanılabilir. Ağı basit ama etkili yapısı sayesinde, doktorlar için karmaşık verilerin daha anlaşılır hale getirilmesi ve klinik karar süreçlerinin desteklenmesi mümkün olmaktadır. AlexNet, günümüzde daha ileri mimarilerin (örneğin ResNet) temelini oluşturarak derin öğrenmenin gelişiminde kritik bir adım olmuştur (Şekil 14) (59).



Şekil 14: AlexNet mimarisi işleyişi


2.4.4.5.2. ResNet

ResNet (Residual Network), derin öğrenme mimarilerinde derinlik arttıkça karşılaşılan "gradyan sönmesi" (vanishing gradient) problemini çözmek için geliştirilmiş bir evrişimli sinir ağı (CNN) mimarisidir. 2015 yılında He ve arkadaşları tarafından tanıtılan bu model, derin öğrenme alanında devrim yaratmıştır ve aynı yıl ImageNet yarışmasını kazanmıştır. ResNet'in temel farkı, "residual bağlantılar" adı verilen bypass (atlama) bağlantıları kullanmasıdır. Bu bağlantılar, bir katmanın çıkışını, birkaç katman sonrasındaki katmana doğrudan ileterek bilgilerin kaybolmasını önler. Böylece daha derin ağlar inşa edilebilir ve ağı performans artırılabilir (60).

Sağlık alanında ResNet, tıbbi görüntülerin sınıflandırılması, hastalık tespiti ve tanı koyma süreçlerinde yaygın olarak kullanılır. Örneğin, ResNet mimarisi, akciğer X-Ray görüntülerinde pnömoni veya COVID-19 gibi hastalıkların tespitinde yüksek doğruluk oranlarıyla etkili sonuçlar verir. Ağın residual bağlantıları, karmaşık tıbbi görüntülerdeki küçük ama kritik özellikleri öğrenmesine yardımcı olarak doktorların karar süreçlerini destekler. Derin katmanlı yapısına rağmen öğrenme sırasında bilgi kaybını minimize eden ResNet, özellikle büyük veri setleri üzerinde yüksek performans gösterir ve tıbbi uygulamalarda önemli bir araç olarak öne çıkar (61). Bu mimarinin başarısı, daha ileri modellerin (DenseNet gibi) geliştirilmesine ilham kaynağı olmuştur.

ResNet18

ResNet18, 18 katmanlı yapısıyla daha hızlı eğitilebilen ve nispeten daha az hesaplama gücü gerektiren bir ResNet versiyonudur. Özellikle daha küçük veri setleri ve hızlı uygulamalar için tercih edilir (Şekil 15) (62).

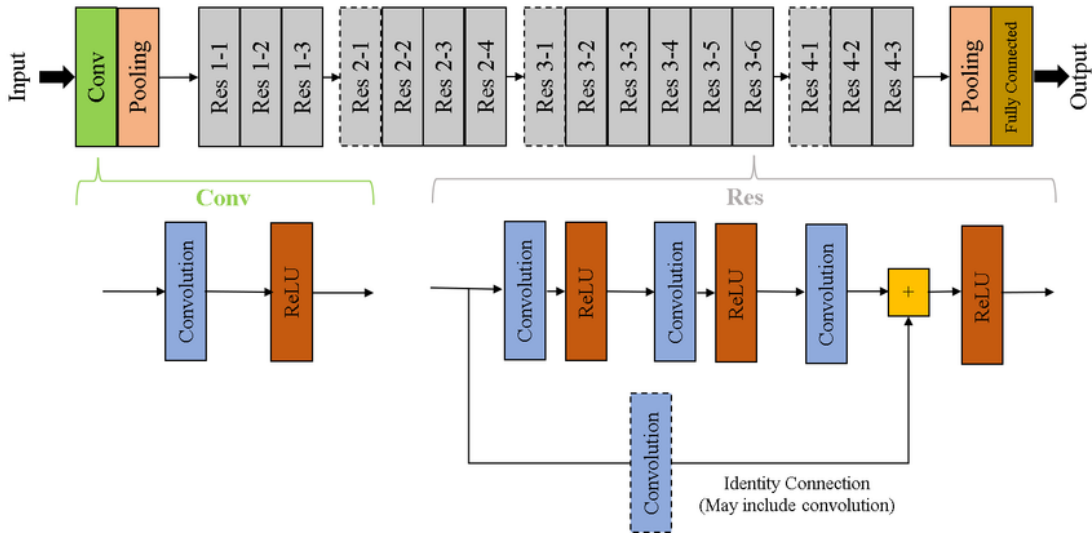


Şekil 15: ResNet18 mimarisi işleyişi

ResNet50

ResNet50, 50 katmanlı derin bir mimariye sahiptir ve "bottle-neck" yapıları sayesinde daha karmaşık özellikleri öğrenebilir. Büyük veri setlerinde yüksek doğruluk oranlarıyla etkili sonuçlar verir (Şekil 16) (63).

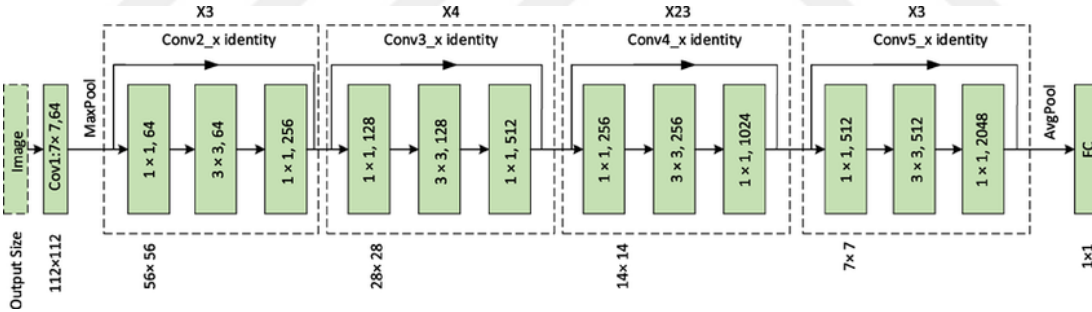
ResNet-50



Şekil 16: ResNet50 mimarisi işleyişi

ResNet101

ResNet101 ise 101 katmanlı derin bir ağdır ve daha büyük ve detaylı veri setleri üzerinde çalışmak için tasarlanmıştır. Özellikle tıbbi görüntülerde küçük detayların öğrenilmesinde etkili bir modeldir (Şekil 17) (64).




Şekil 17: ResNet101 mimarisi işleyişi

2.4.4.5.3. MobileNet

MobileNet, özellikle mobil cihazlar ve gömülü sistemler gibi sınırlı donanım kaynaklarına sahip platformlarda derin öğrenme uygulamaları için tasarlanmış hafif bir evrişimli sinir ağı (CNN) mimarisidir. Google tarafından 2017 yılında geliştirilen bu mimari, düşük hesaplama gücü ve enerji tüketimi gerektirirken yüksek doğruluk sağlamayı hedefler. MobileNet'in temel yeniliği, hesaplama yükünü azaltmak için "derinlik ayrık konvolüsyon" (depthwise separable convolution) adı verilen bir yöntem

kullanmasıdır (65). Bu yöntem, geleneksel konvolüsyon işlemini iki ayrı adımda gerçekleştirerek ağı daha hızlı çalışmasını sağlar (Şekil 18) (66).

Sağlık alanında MobileNet, sınırlı donanıma sahip cihazlarda tıbbi görüntü analizi ve tanı süreçlerinde kullanılabilir. Örneğin, taşınabilir bir ultrason cihazında görüntü sınıflandırma veya cilt lezyonlarını tespit etme gibi uygulamalar için idealdir. Mobil cihazlarla entegre çalışabilmesi, kırsal ve kaynakların sınırlı olduğu bölgelerde klinik karar süreçlerine destek olmasını sağlar. MobileNet'in bu esnek ve verimli yapısı, sağlık hizmetlerinde hızlı, erişilebilir ve ekonomik çözümler sunar (67).



Şekil 18: MobileNet mimarisi işleyişi

3. GEREÇ VE YÖNTEM

3.1. Çalışma Tasarımı

Bu araştırma, acil servise başvuran tibia plato kırığı ön tanısı olan olguların radyografik görüntülerinin yapay zeka destekli derin öğrenme algoritmaları ile değerlendirilmesi amacıyla tasarlanmış, retrospektif bir gözlemsel çalışmadır. Çalışma grubu üzerinde gözlemsel yöntemlerle veri toplanmış ve mevcut tıbbi görüntüler üzerinde analiz gerçekleştirilmiştir.

İzmir Kâtip Çelebi Üniversitesi Sağlık Araştırmalar Etik Kurulundan onay alınmıştır. Çalışmaya 17/10/2024 Tarih ve 0184 numaralı etik kurul onayı alındıktan sonra başlanmıştır. Çalışma 21/10/2024 – 12/02/2025 tarihleri arasında gerçekleştirilmiştir.

3.2. Çalışma Popülasyonu

Çalışmaya son 15 yılda erişkin yaş (18 yaşından büyük olan) ve İzmir Katip Çelebi Üniversitesi Atatürk Eğitim ve Araştırma Hastanesi acil servisinde tibia plato kırığı ön tanısı konulan hastalar dahil edilmiştir. Tibia plato kırığı tanısı alan 317 (kırık grubu) hasta ve tibia plato kırık tanısı almayan 339 (normal grup) normal hasta olmak üzere toplam 656 hasta çalışmaya dahil edilmiştir. Tüm hastaların diz ön-arka (AP) ve diz yan (lateral) standart radyografileri mevcuttu. Tüm radyografiler, tibia plato kırığı varlığı veya yokluğu açısından 10 yıllık deneyime sahip bir acil uzmanı tarafından değerlendirildi. Daha sonra kırığın varlığı veya yokluğu çekilmiş olan BT ile doğrulandı. Verilerinde eksiklik olanlar, 18 yaş altı hastalar, ileri gonartrozu olanlar, gebeler çalışma dışı bırakılmıştır.

3.3. Çalışma Dizaynı

Bu çalışmada, X-Ray görüntülerinden tibia plato kırığını (TPK) tanımlayabilecek yüksek performanslı bir derin öğrenme modeli oluşturmak ve geleneksel yöntemlere kıyasla tespit doğruluğunu artırmak amaçlanmıştır. Görüntüler İzmir Katip Çelebi Üniversitesi Atatürk Eğitim ve Araştırma Hastanesi'nde bulunan Hastane Bilgi Yönetim Sistemi (HBYS) altyapısından JPEG formatıyla indirilerek elde edilmiştir. Elde edilen görüntüler minimum: 865-2192 piksel, maksimum: 4248-3480 piksel olarak kaydedilmiştir. Ardından bu görüntüler AlexNet, ResNet18, ResNet50, ResNet101 ve MobileNet Evrişimli Sinir Ağı (CNN) mimarileri ile eğitilerek tibia plato kırığı tanısında en doğru yaklaşım elde edilmeye çalışılmıştır. Bu derin ağlar, görüntü verilerini

tanımlayabilir ve ilgili ayırt edici özellikleri doğrudan ham görüntülerden çıkarabilmektedir (4) (68).

3.4. Veri Kümesi, Veri Ön İşleme ve Tibia Plato Kırığı Tespit Mimarisi

Çalışmamızda tibia plato kırığı olan ve kırık bulgusu olmayan normal röntgen (X-Ray) görüntüleri kullanılmıştır. Bu kapsamda görüntüler hem önden hem de yandan çekilmiş ve bu sayede 2 farklı pozisyondan çekilmiş X-Ray görüntü veri seti elde edilmiştir.

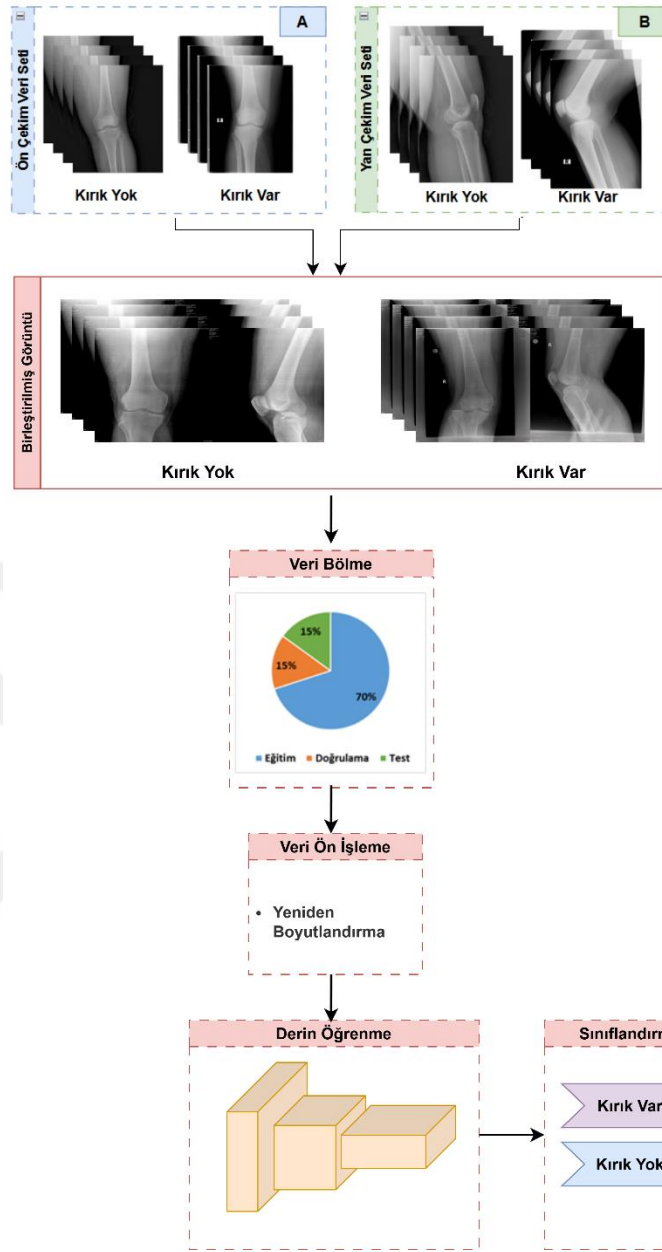
Çalışmada tibia plato kırığı tespiti için 2 farklı yaklaşım önerilmiştir;

Görüntü aşamasında birleştirme: Ön ve Yan çekim X-Ray görüntülerinin birleştirilerek derin öğrenme mimarileri kullanılarak eğitilmesi.

Öznitelik aşamasında birleştirme: Önden ve Yandan çekilen X-Ray görüntülerinin ayrı ayrı derin öğrenme mimarisinde eğitilmesi ile elde edilen derin özniteliklerin birleştirilerek sınıflandırılması.

Çalışmamız kapsamında tibia plato kırığı tespiti için kullanılan CNN modelleri ve model sağlamlıklarını test etmek için yürütülen performans değerlendirmeleri MATLAB 2024a yazılımı kullanılarak gerçekleştirilmiştir.

3.4.1. Görüntü Aşamasında Birleştirme

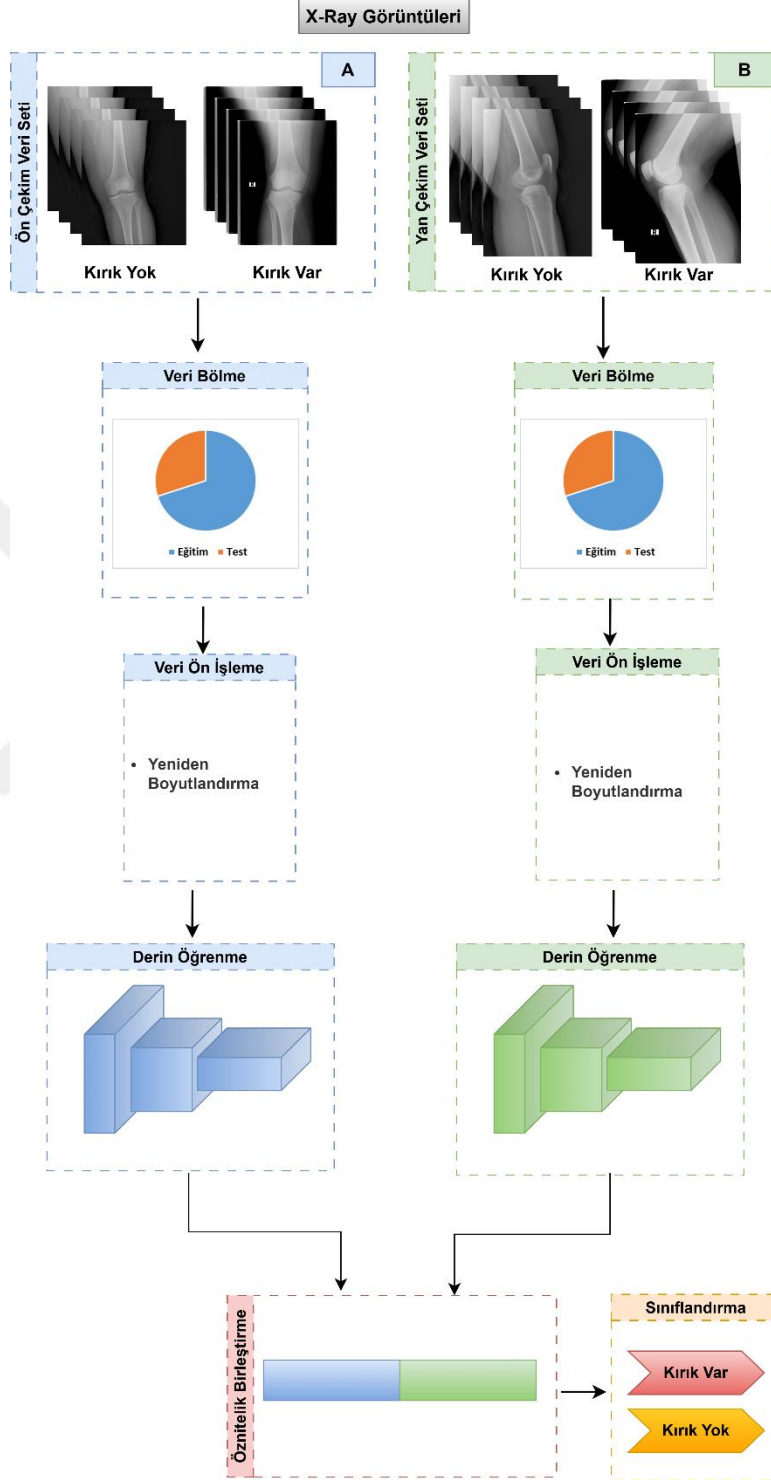


Şekil 19: Önerilen görüntü aşamasında birleştirme temelli modelin genel çerçevesi

Önerilen ilk yaklaşımda, yandan ve önden çekilmiş X-Ray görüntüleri derin öğrenme mimarisine girdi olarak verilmeden önce birleştirilerek “*birleştirilmiş görüntü*” kümesi oluşturulmuştur. Ardından birleştirilmiş görüntü kümesi %70 (222 kırık, 237 normal), %15 (47 kırık, 51 normal) ve %15’i (48 kırık, 51 normal) eğitim, doğrulama ve test kümeleri olmak üzere parçalanmıştır. Görüntüler derin öğrenme mimarilerinin giriş katmanının boyutlarına uygun olacak şekilde (224.224) piksele yeniden boyutlandırılmıştır. Çalışma kapsamında AlexNet, ResNet18, ResNet50, ResNet101, ve

MobileNet gibi literatürde sıklıkla kullanılan derin öğrenme mimarileri kullanılarak tibia plato kırığı tespiti gerçekleştirilmiştir.

3.4.2. Öznitelik Aşamasında Birleştirme



Şekil 20: Önerilen öznitelik aşamasında birleştirme temelli modelin genel çerçevesi

Ön işleme adımında, ilk olarak önden ve yandan çekilmiş X-Ray görüntüleri ayrı ayrı %70 (222 kırık, 237 normal), %30'u (95 kırık, 102 normal) eğitim ve test kümeleri

olmak üzere ikiye ayrılmıştır. Daha sonra giriş görüntüleri ilgili derin öğrenme mimarisinin giriş katmanının boyutlarına uygun olacak şekilde (224.224) piksele yeniden boyutlandırılmıştır. Ön işleme aşamasının ardından önden çekilmiş ve yandan çekilmiş görüntülerden oluşan 2 veri kümesi (Şekil 20) ayrı ayrı derin öğrenme mimarilerine girdi olarak verilmiştir. Derin öğrenme mimarilerinin tam bağlı katmanında elde edilen öznitelikler (1000 öznitelik) birleştirilerek birleştirilmiş öznitelik kümesi (2000 öznitelik) elde edilmiştir. Birleştirilmiş öznitelikler Destek Vektör Makinesi (DVM) sınıflandırıcı kullanılarak sınıflandırılmış ve mimarinin eğitim ve doğrulama süreci tamamlanmıştır. Test için ayrılmış veri kümesi eğitilmiş mimari ile test edilmiş ve önerilen yöntemin tibia plato kırığı tespiti için test performansı değerlendirilmiştir. Çalışma kapsamında AlexNet, ResNet18, ResNet50, ResNet101 ve MobileNet gibi literatürde sıklıkla kullanılan derin öğrenme mimarileri kullanılarak tibia plato kırığı tespiti gerçekleştirilmiştir.

3.5. Çalışmada Kullanılan Performans Metrikleri

Derin öğrenme mimarilerinin eğitilmesi sonrası performansı test veri setinde değerlendirilecektir. Ağ performansını ölçmek için, Doğruluk (ACC), Duyarlılık (SEN), Özgüllük (SPE), Pozitif tahmin değeri (PPV) ve Negatif tahmin oranı (FDR) gibi çeşitli standart performans ölçütleri kullanılacaktır. Kullanılacak olan bu performans ölçütlerinin formülleri aşağıda verilmiştir (Şekil 21).

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \times 100\%$$

$$SEN = \frac{TP}{TP + FN} \times 100\%$$

$$SPE = \frac{TN}{TN + FP} \times 100\%$$

$$PPV = \frac{TP}{TP + FP} \times 100\%$$

$$FDR = \frac{FP}{TP + FP} \times 100\%$$

Şekil 21: Literatürde sık kullanılan istatistiksel ölçütler

Formüllerde kullanılan terimlerin tanımları şu şekildedir;

TP (Doğru Pozitifler): Doğru bir şekilde tahmin edilen pozitif vaka sayısı.

TN (Doğru Negatifler): Doğru bir şekilde tahmin edilen negatif vaka sayısı.

FP (Yanlış Pozitifler): Yanlış bir şekilde tahmin edilen pozitif vaka sayısı.

FN (Yanlış Negatifler): Yanlış bir şekilde tahmin edilen negatif vaka sayısı.

Doğruluk (Accuracy): Modelin tüm sınıflandırmalar içinde doğru tahmin ettiği örneklerin oranını ölçmek için kullanılır. Genel performansı değerlendirmek için yaygın olarak kullanılan bir metriktir. Ancak, dengesiz veri kümelerinde yanıltıcı olabilir.

Duyarlılık (Sensitivity): Gerçek pozitif örnekler arasında modelin doğru tahmin ettiği pozitiflerin oranını ölçmek için kullanılır. Modelin pozitif sınıfa ait örnekleri ne kadar iyi yakaladığını gösterir.

Özgüllük (Specificity): Doğru bir şekilde sınıflandırılan negatif örneklerin oranını ölçmek için kullanılır. Yanlış pozitiflerin (FP) düşük tutulmasını sağlamak açısından önemlidir.

Pozitif Prediktif Değer (PPV): Pozitif olarak tahmin edilen örnekler arasında gerçekten pozitif olanların oranını ölçmek için kullanılır. Modelin yaptığı pozitif tahminlerin ne kadar güvenilir olduğunu gösterir.

Negatif tahmin oranı (FDR): Pozitif olarak tahmin edilen örnekler arasında yanlış pozitif (FP) olanların oranını ölçmek için kullanılır. Modelin yaptığı pozitif tahminlerin ne kadarının hatalı olduğunu gösterir. FDR'nin düşük olması, modelin yanlış pozitif tahmin yapma olasılığının az olduğunu gösterir.

validation confusion matrix

		TP 43 43.9%	FP 2 2.0%	PPV 95.6% 4.4% FDR
Output Class	fraktür olanlar			
	fraktür olmayanlar	FN 4 4.1%	TN 49 50.0%	92.5% 7.5%
		SEN 91.5% 8.5%	SPE 96.1% 3.9%	ACC 93.9% 6.1%
		fraktür olanlar	fraktür olmayanlar	
		Target Class		

Şekil 22: Performans metriklerinin karmaşıklık matrisi örneği üzerinde gösterimi

3.6. Çalışmada Kullanılan Hiper-Parametreler

Bir dizi hiperparametre, araştırmada kullanılan derin öğrenme mimarilerinin eğitimi ve geliştirilmesinde en iyi konfigürasyonu belirlemek ve performansı en verimli hale getirmek için dikkatli bir şekilde ayarlandı. Aşağıdaki hiperparametreler, yüksek doğruluk oranına ulaşmak için ayarlanıp test edilmiştir;

Optimizasyon Algoritması: Çalışmamızda stokastik bir çözücü olan Stochastic gradient descent with momentum (SGDM) algoritması optimizasyon algoritması olarak kullanılmıştır.

Mini-Batch Boyutu: Modelin iç parametreleri güncellenmeden önce işlenen örneklerin miktarı, mini batch boyutuyla belirlenir. Çalışmada kullanılan mimari modellerinde, eğitim verimliliğini ve modelin performansını dengeleyen en iyi değeri belirlemek için çeşitli mini batch boyutları denenmiştir. Sonuç olarak, tüm mimariler için mini akış boyutu 32 olarak belirlenmiştir.

Maksimum Epok Sayısı: Modelin eğitim sürecinde veri kümesinin tamamının bir kez işlenip analiz edilmesi, bir epok olarak bilinir. Maksimum epok sayısı, modelin eğitim

verilerinden etkili bir şekilde öğrenmesini sağlamak için yeterli süreyi sağlayacak şekilde ayarlanmıştır. Çalışmamızda kullanılan mimariler için maksimum epok 20 olarak seçilmiştir.

Öğrenme Hızı (Learning Rate): Adım boyutu, öğrenme hızı olarak da bilinen önemli bir hiperparametre tarafından gradyan inişinde kontrol edilir. Modelin iyi bir şekilde optimizasyonunu sağlarken, dalgalanma ve sapma olmadan doğru bir öğrenme hızı bulmak için çok sayıda değeri test etmek gerekir. Çalışmamızda, ilk öğrenme hızı “ $1 * e^{-4}$ ” olarak belirlenmiştir.

Karıştırma (Shuffle): Shuffle, veri kümesinin veya katmanların sırasının rastgele değiştirilmesidir. Shuffle, modelin daha iyi genelleme yapmasını ve overfitting olarak bilinen aşırı öğrenmeyi önlemesini sağlar. Eğitim başlamadan önce, shuffle içeren bir mimaride veri seti karıştırılır. Çalışmamız kapsamında incelenen mimarilerin tümü için “every-epoch” shuffle kullanılmıştır.

Doğrulama Frekansı (Validation Frequency): Modelin doğrulama verisi üzerinde ne sıklıkla test edileceğini belirleyen doğrulama frekansıdır. Çalışmamızda her mimari için doğrulama frekansı beş olarak belirlenmiştir ve her beş iterasyonda bir doğrulama gerçekleştirilmiştir.

4. BULGULAR

Çalışmada tibia plato kırığı tespiti için 2 farklı yaklaşım önerilmiştir;

Görüntü aşamasında birleştirme: Ön ve Yan çekim X-Ray görüntülerinin birleştirilerek derin öğrenme mimarileri kullanılarak eğitilmesi.

Öznitelik aşamasında birleştirme: Önden ve Yandan çekilen X-Ray görüntülerinin ayrı ayrı derin öğrenme mimarisinde eğitilmesi ile elde edilen derin özniteliklerin birleştirilerek sınıflandırılması.

4.1. Görüntü Aşamasında Birleştirme

Önerilen yaklaşımın doğrulama ve test veri setleri üzerindeki tibia plato kırığı tespit performansı farklı derin öğrenme mimarileri için Tablo 3, Tablo 4, Tablo 5, Tablo 6 ve Tablo 7’de verilmiştir.

Tablo 3: AlexNet doğrulama ve test veri setleri için performans sonuçları

	AlexNet									
	Doğrulama					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	90.80	89.40	92.20	91.30	8.70	84.80	89.60	80.40	81.10	18.90
Yan	87.80	78.70	96.10	94.90	5.10	83.80	87.50	80.40	80.80	19.20
Birleştirilmiş	87.80	85.10	90.20	88.90	11.10	87.90	77.10	98.00	97.40	2.60

Tablo 4: ResNet18 doğrulama ve test veri setleri için performans sonuçları

	ResNet18									
	Doğrulama					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	88.80	87.20	90.20	89.10	10.90	87.90	93.80	82.40	83.30	16.70
Yan	90.80	85.10	96.10	95.20	4.80	86.90	85.40	88.20	87.20	12.80
Birleştirilmiş	89.80	93.60	86.30	86.30	13.70	93.90	89.60	98.00	97.70	2.30

Tablo 5: ResNet50 doğrulama ve test veri setleri için performans sonuçları

	ResNet50									
	Doğrulama					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	89.80	89.40	90.20	89.40	10.60	88.90	89.60	88.20	87.80	12.20
Yan	91.80	87.20	96.10	95.30	4.80	86.90	93.80	80.40	81.80	18.20
Birleştirilmiş	85.70	93.60	78.40	80.00	20.00	91.90	83.30	100.00	100.00	0.00

Tablo 6: ResNet101 doğrulama ve test veri setleri için performans sonuçları

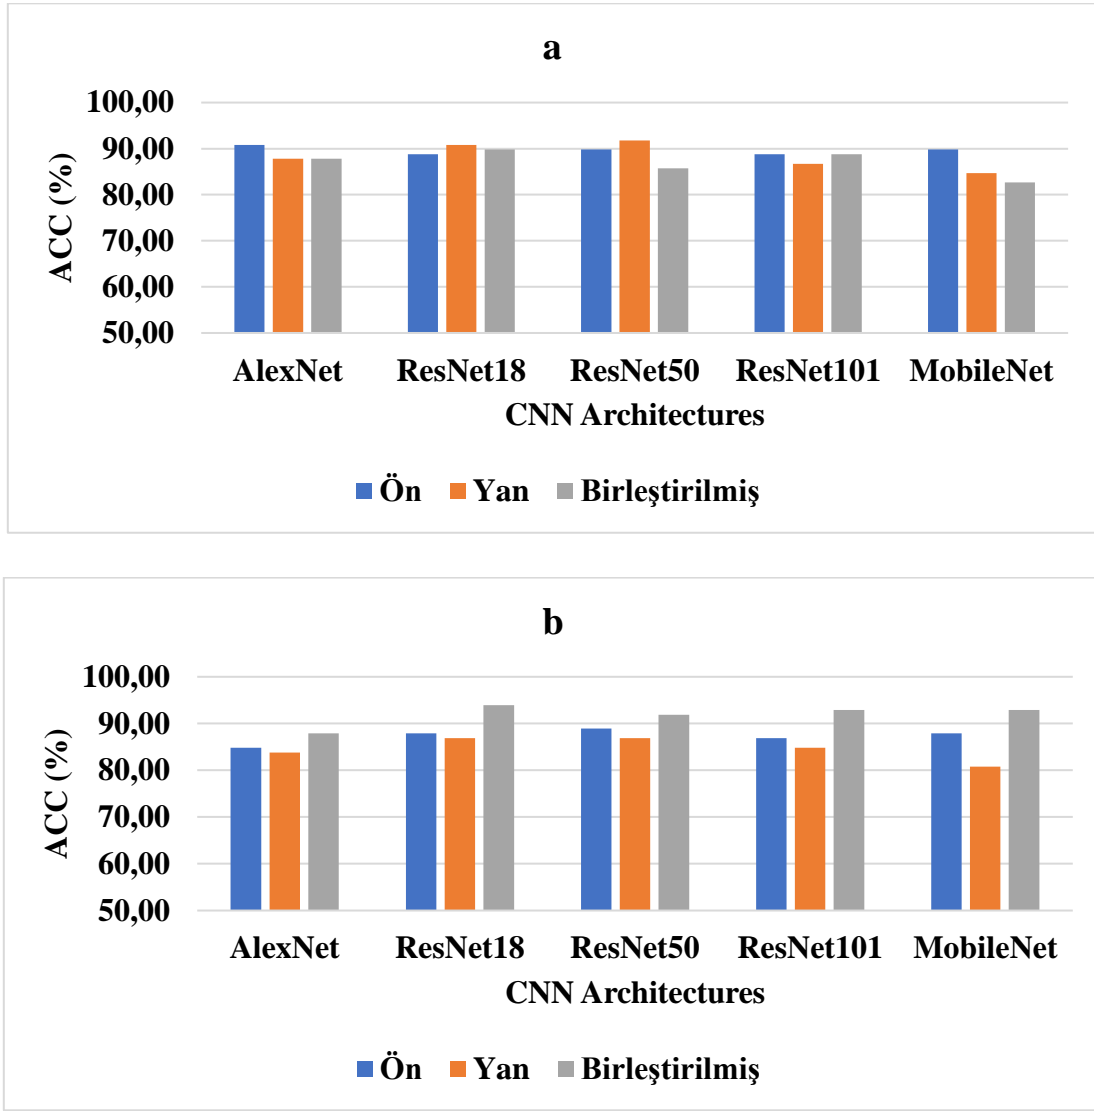
ResNet101										
	Doğrulama					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	88.80	85.10	92.20	90.90	9.10	86.90	89.60	84.30	84.30	15.70
Yan	86.70	85.10	88.20	87.00	13.00	84.80	89.60	80.40	81.10	18.90
Birleştirilmiş	88.80	95.70	82.40	83.30	16.70	92.90	89.60	96.10	95.60	4.40

Tablo 7: MobileNet doğrulama ve test veri setleri için performans sonuçları

MobileNet										
	Doğrulama					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	89,80	87,20	92,20	91,10	8,90	87,90	93,80	82,40	83,30	16,70
Yan	84,70	78,70	90,20	88,10	11,90	80,80	77,10	84,30	82,20	17,80
Birleştirilmiş	82,70	85,10	80,40	80,00	20,00	92,90	85,40	100,00	100,00	0,00

Tablolardan ResNet temelli mimarilerin tibia plato kırığı tespit performanslarının diğer mimarilere göre daha yüksek olduğu görülmektedir. Tüm performans metrikleri dikkate alındığında ise hem doğrulama hem de test veri setleri için en yüksek performanslar ResNet18 mimarisi kullanılarak elde edilmiştir.

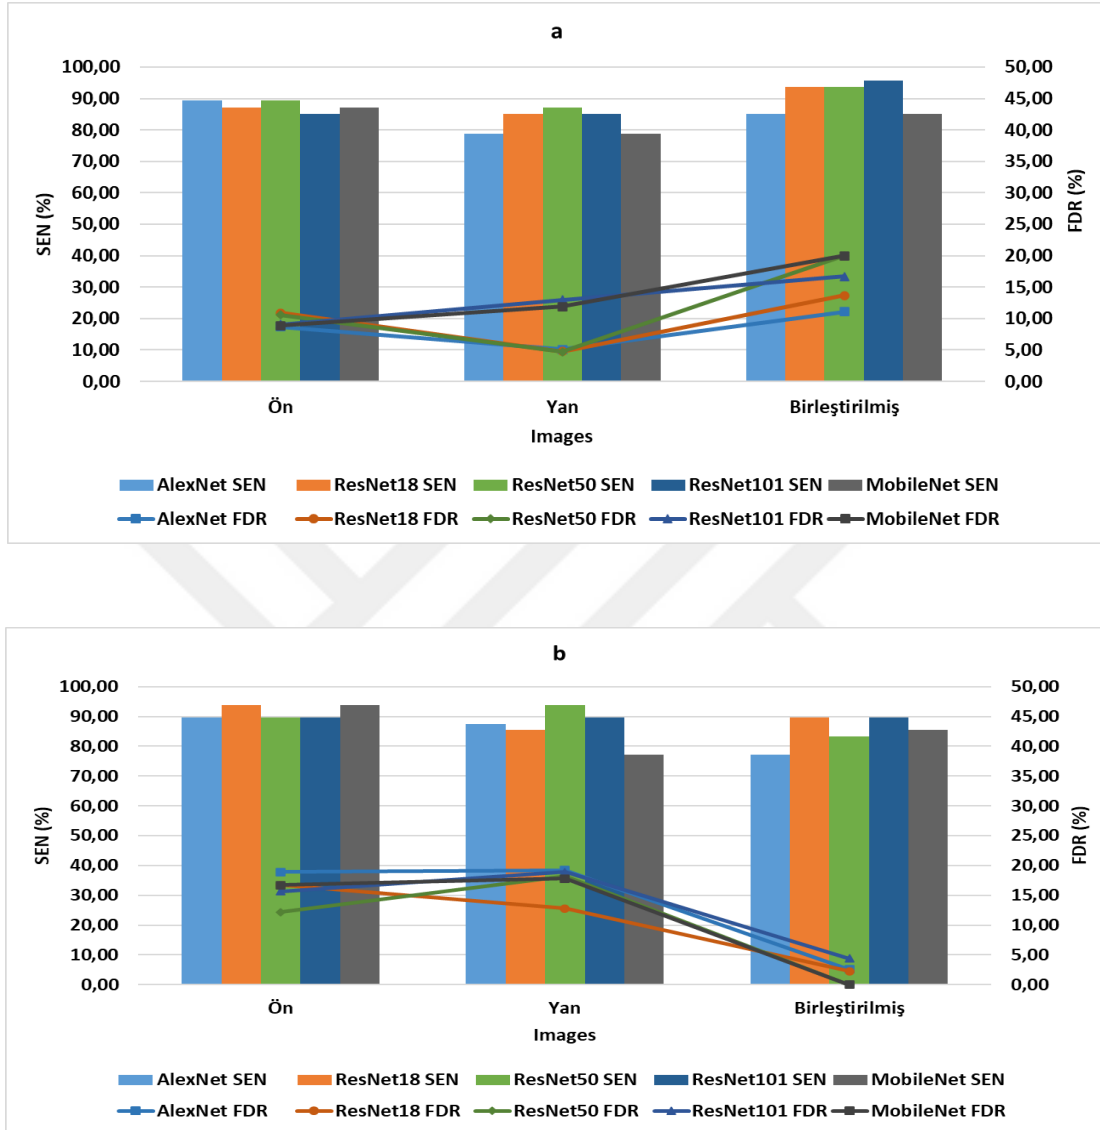
Mimarilerin tibia plato kırığı tespit performansını daha net karşılaştırabilmek için doğrulama ve test veri setleri için ACC bar grafikleri Şekil 23'te verilmiştir. Doğrulama veri seti için en yüksek tibia plato kırığı tespit doğruluğu % 91.8 ile yandan çekilmiş X-Ray görüntüleri ve ResNet50 mimarisi kullanılarak elde edilmiştir. Ancak Test veri seti için hiç görmediği X-Ray görüntülerinde birleştirilmiş görüntüler ve ResNet18 mimarisi kullanılarak % 93.9 tibia plato kırığı tespit doğruluğu elde edilmiştir. Test veri setinde tüm mimariler için birleştirilmiş görüntüler kullanılarak sadece Önden ve sadece Yandan çekilmiş X-Ray görüntüleri kullanılarak elde edilen tespit doğruluğundan çok daha yüksek tespit doğrulukları elde edilmiş olması dikkat çekicidir.



Şekil 23: Derin öğrenme mimarilerinin (a) doğrulama ve (b) test veri setleri için tibia plato kırığı tespit doğruluklarının (ACC) bar grafik gösterimleri.

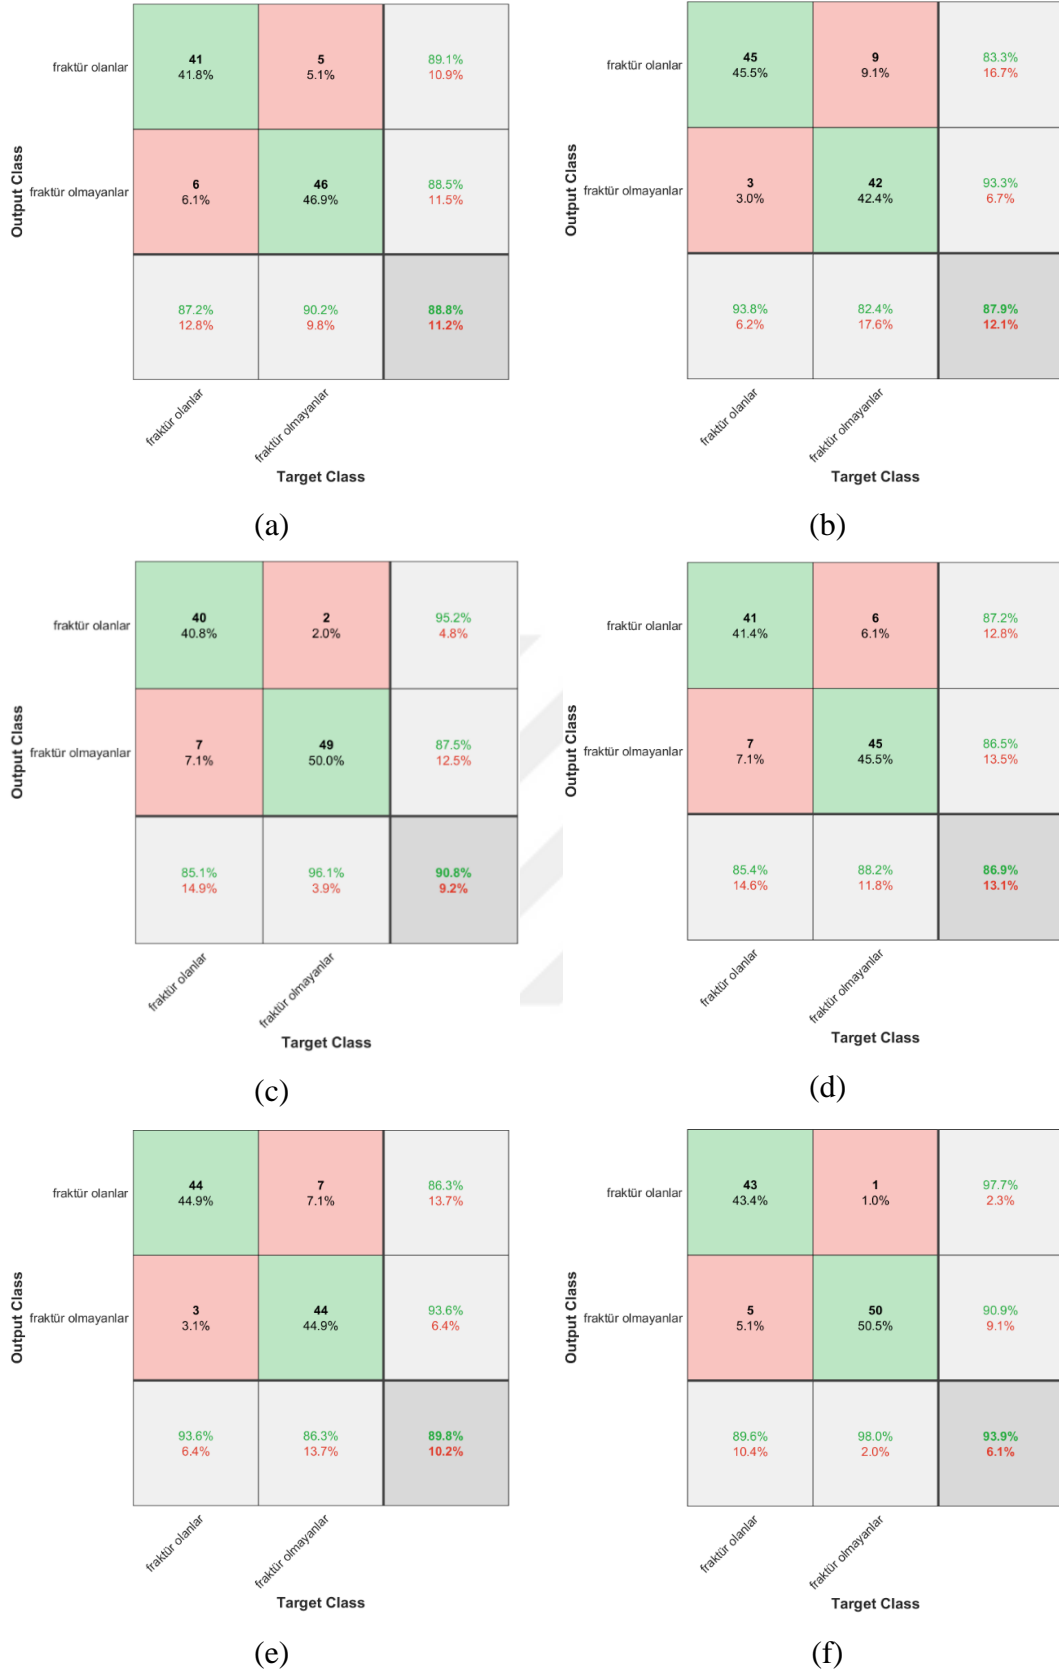
Önerilen yöntemin performansını ortaya net bir şekilde koyabilmek için sadece yöntemlerin doğruluk karşılaştırmasını vermek yetersizdir. Doğru tespit edilen Tibia plato kırığı X-Ray görüntülerinin oranı (SEN) ve Yanlışlıkla Tibia plato kırığı var olarak etiketlenen aslında kırık olmayan X-Ray görüntülerinin oranı (FDR) bize önerilen yöntemlerin performansları hakkında daha detaylı bilgiler sunmaktadır. Önerilen yöntemlerin doğrulama ve test veri setleri için SEN ve FDR karşılaştırması Şekil 24'te verilmiştir. Burada AlexNet hariç tüm yöntemler için Birleştirilmiş görüntülerin doğrulama veri setlerinin SEN değerlerinin Ön ve Yandan çekilmiş X-Ray görüntülerinin doğrulama veri seti SEN değerlerinden daha yüksek olması dikkat çekicidir. Test veri seti için ise Birleştirilmiş görüntüler için SEN değerlerinde düşme olmasına rağmen çok küçük FDR değerlerine ulaşılmış olması önemli bir ayrıntıdır. Hem yüksek SEN hem de

daha düşük FDR değerleri (Doğrulama: %93.60 SEN, %13.70 FDR; Test: %89.60 SEN, %2.60 FDR) sağlamış olması nedeniyle ResNet18 mimarisi bu veri set için en iyi derin öğrenme mimarisi olarak öne çıkmaktadır.

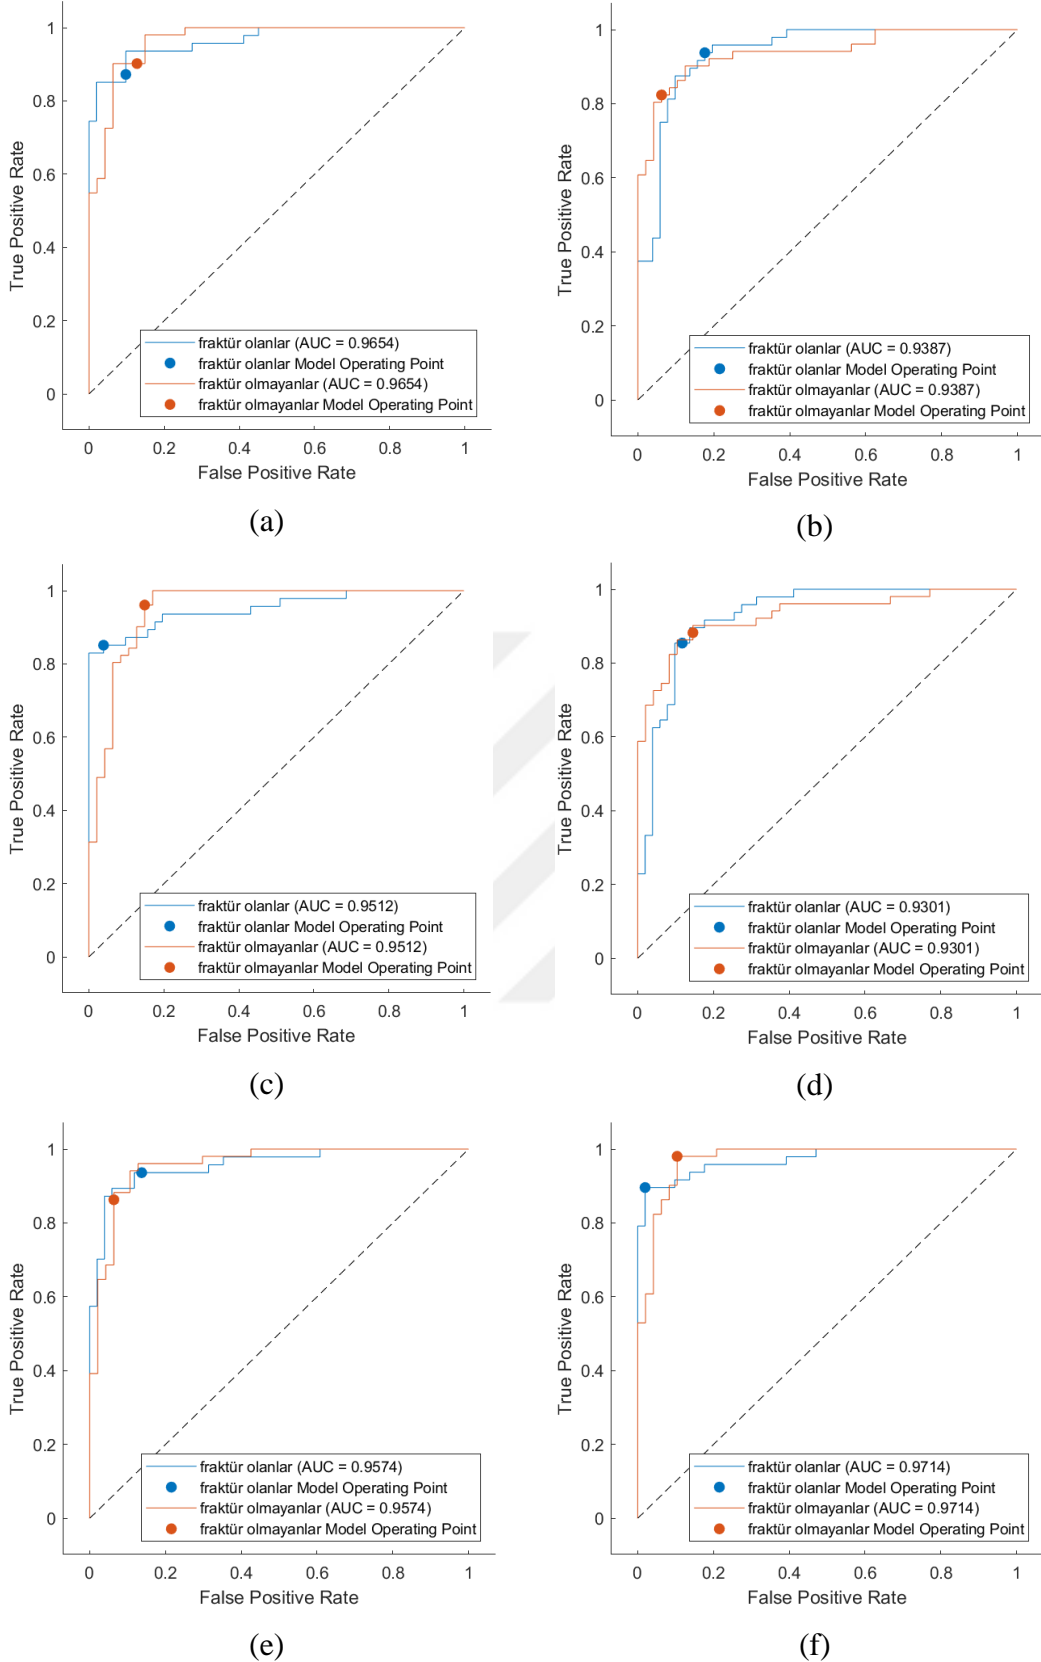


Şekil 24: Derin öğrenme mimarilerinin (a) doğrulama ve (b) test veri setleri için tibia plato kırığı tespit Hassasiyet (SEN) ve Negatif tahmin oranı (FDR) karşılaştırması

ResNet18 mimarisi ve Önden çekilmiş, Yandan çekilmiş ve Birleştirilmiş X-Ray görüntüleri kullanılarak elde edilmiş karmaşıklık matrisleri Şekil 25'te verilmiştir. Burada da görüleceği gibi birleştirilmiş görüntüler kullanılarak hem tibia plato kırığı olan hem de tibia plato kırığı olmayan X-Ray görüntülerinin tespiti daha yüksek doğrulukla gerçekleştirilmiştir. Birleştirilmiş görüntülerin test veri seti için 48 kırık olan görüntüden 43'ü, 51 kırık olmayan görüntüden 50'si doğru şekilde tespit edilmiştir.



Şekil 25: ResNet18 mimarisinin (a),(c),(e) doğrulama ve (b), (d),(f) test veri setleri için tibia plato kırığı tespit karmaşıklık matrisleri. Burada (a, b) Önden çekilmiş X-Ray görüntüleri, (c, d) Yandan çekilmiş X-Ray görüntüleri ve (e, f) Birleştirilmiş X-Ray görüntüleri kullanılarak elde edilmiştir.



Şekil 26: ResNet18 mimarisinin (a),(c),(e) doğrulama ve (b),(d),(f) test veri setleri için tibia plato kırığı tespit ROC eğrileri. Burada (a, b) Önden çekilmiş X-Ray görüntüleri, (c, d) Yandan çekilmiş X-Ray görüntüleri ve (e, f) Birleştirilmiş X-Ray görüntüleri kullanılarak elde edilmiştir.

4.2. Öznitelik Aşamasında Birleştirme

Önerilen yaklaşımın eğitim ve test veri setleri üzerindeki tibia plato kırığı tespit performansı farklı derin öğrenme mimarileri için Tablo 8, 9, 10, 11 ve 12’te verilmiştir.

Tablo 8: AlexNet eğitim ve test veri setleri için performans sonuçları

	AlexNet									
	Eğitim					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	86.93	81.98	91.56	90.10	9.90	83.25	80.00	86.27	84.44	15.56
Yan	84.97	80.63	89.03	87.32	12.68	78.68	68.42	88.24	84.42	15.58
Birleştirilmiş	88.67	85.59	91.56	90.48	9.52	84.77	80.00	89.22	87.36	12.64

Tablo 9: ResNet18 eğitim ve test veri setleri için performans sonuçları

	ResNet18									
	Eğitim					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	87.80	84.23	91.14	89.90	10.1	86.80	83.16	90.20	88.76	11.24
Yan	89.98	88.74	91.14	90.37	9.63	86.80	83.16	90.20	88.76	11.24
Birleştirilmiş	89.76	86.94	92.41	91.47	8.53	87.82	87.37	88.24	87.37	12.63

Tablo 10: ResNet50 eğitim ve test veri setleri için performans sonuçları

	ResNet50									
	Eğitim					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	87.36	82.43	91.98	90.59	9.41	88.83	87.37	90.20	89.25	10.75
Yan	88.02	84.68	91.14	89.95	10.05	88.83	84.21	93.14	91.95	8.05
Birleştirilmiş	89.11	83.33	94.51	93.43	6.57	91.37	87.37	95.10	94.32	5.68

Tablo 11: ResNet101 eğitim ve test veri setleri için performans sonuçları


	ResNet101									
	Eğitim					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	86.49	81.08	91.56	90.00	10.00	86.29	83.16	89.22	87.78	12.22
Yan	90.20	88.29	91.98	91.16	8.84	85.28	83.16	87.25	85.87	14.13
Birleştirilmiş	89.32	85.14	93.25	92.20	7.80	88.32	88.42	88.24	87.50	12.50

Tablo 12: MobileNet eğitim ve test veri setleri için performans sonuçları

	MobileNet									
	Eğitim					Test				
	ACC	SEN	SPE	PPV	FDR	ACC	SEN	SPE	PPV	FDR
Ön	86.71	82.43	90.72	89.27	10.73	86.80	88.42	85.29	84.85	15.15
Yan	86.93	81.98	91.56	90.10	9.90	88.32	84.21	92.16	90.91	9.09
Birleştirilmiş	87.15	83.33	90.72	89.37	10.63	88.32	89.47	87.25	86.73	13.27

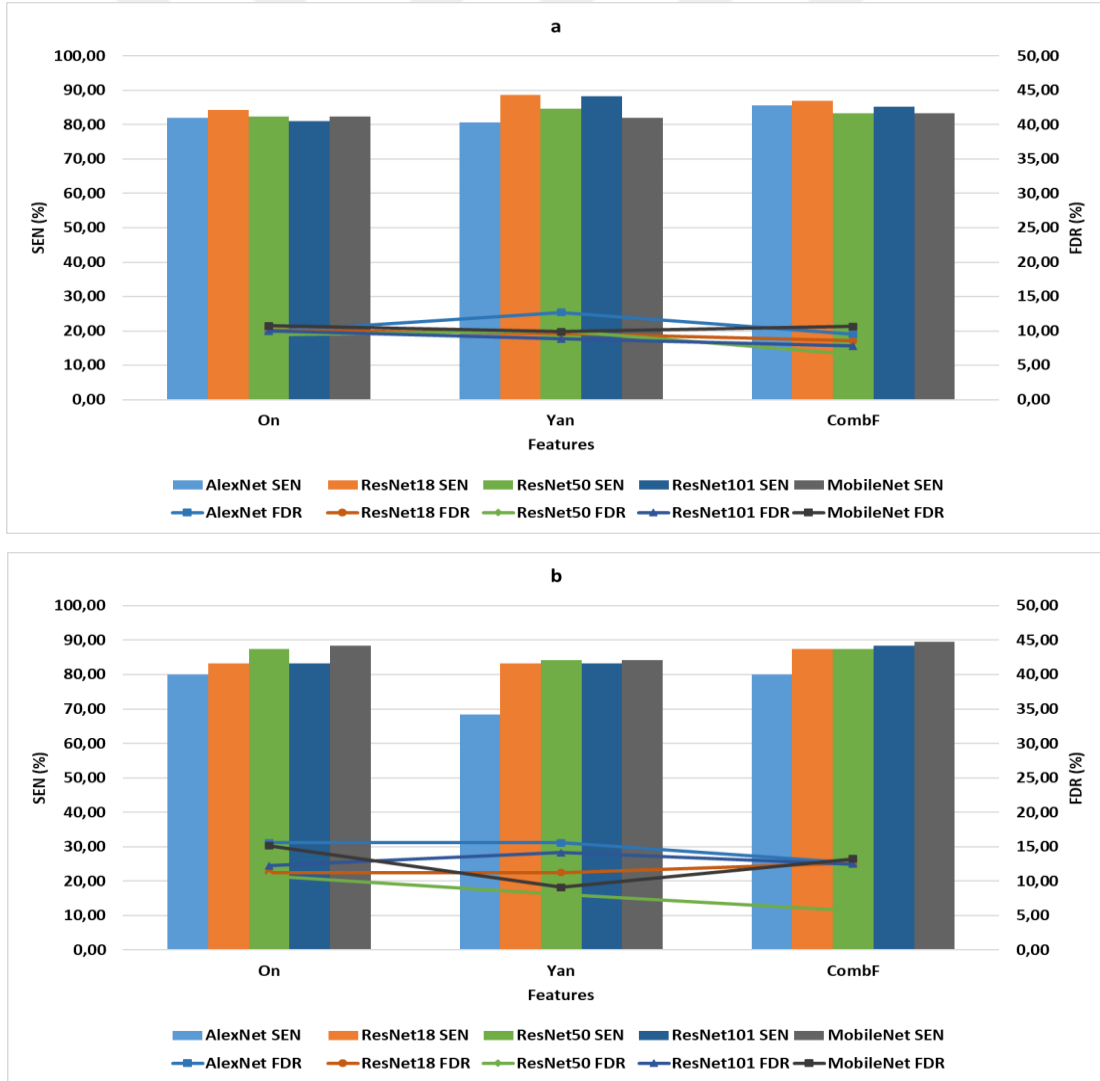
Tablolardan da anlaşılacağı gibi ResNet temelli derin öğrenme mimarilerin Tibia plato kırığı tespit performansı diğer mimarilere göre daha yüksektir. En iyi performans eğitim veri seti için %90.20 ACC ile Yan görüntülerden ResNet101 mimarisi kullanılarak elde edilirken test veri seti için %91.37 ACC ile Birleştirilmiş (CombF) görüntülerden ResNet50 mimarisi kullanılarak elde edilmiştir.

Daha detaylı bir karşılaştırma ortaya koyabilmek için yöntemlerin tibia plato kırığı tespit doğruluğu bar grafiği karşılaştırması Şekil 27’de verilmiştir. Eğitim veri seti için ResNet18 mimarisi kullanılarak Ön, Yan ve Birleştirilmiş (CombF) için sırası ile %87.80, %89.98, %89.76 oranında ortalama olarak en yüksek tibia plato kırığı tespit doğruluğu elde edilirken, test veri seti için en yüksek tibia plato kırığı tespit doğruluğu ResNet50 mimarisi kullanılarak Ön, Yan, ve Birleştirilmiş (CombF) için sırası ile %88.83, %88.83, %91.37 olarak elde edilmiştir.



Şekil 27: Derin öğrenme mimarilerinin (a) eğitim ve (b) test veri setleri için tibia plato kırığı tespit doğruluklarının (ACC) bar grafik gösterimleri

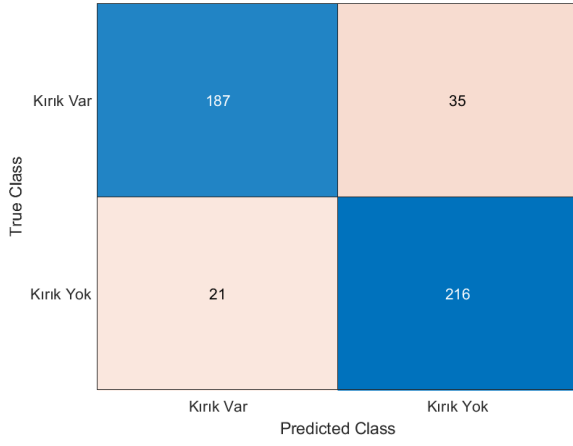
DVM sınıflandırıcı kullanılarak elde edilen derin özneteliklerden doğru tespit edilen Tibia plato X-Ray görüntülerinin oranı (SEN) ve Yanlışlıkla Tibia plato kırığı var olarak etiketlenen aslında kırık olmayan X-Ray görüntülerinin oranı (FDR) olarak hesaplanmaktadır. Önerilen yöntemlerin eğitim ve test veri setleri için SEN ve FDR karşılaştırması Şekil 28’de verilmiştir. Burada Yan görüntüler için elde edilen derin özneteliklerin DVM sınıflandırma hassasiyeti (SEN) tüm mimariler için daha yüksekken en yüksek SEN değeri (%88.74) yine Yan görüntüler kullanılarak ResNet18 mimarisi ile elde edilmiştir. Ancak test veri seti için tüm yöntemlerin Birleştirilmiş (CombF) performanslarının daha yüksek olması da dikkat çekicidir. Tüm durumlar dikkate alındığında hem yüksek SEN hem de düşük FDR değerleri (Eğitim: %86.94 SEN, %8.53 FDR; Test: %87.37 SEN, %12.63 FDR) sağlamış olması, eğitim ve test veri performanslarının daha tutarlı olması ve daha hızlı eğitilebilir olması nedeniyle ResNet18 mimarisi bu yöntem için de en iyi derin öğrenme mimarisi olarak öne çıkmaktadır.




Şekil 28: Derin öğrenme mimarilerinin (a) eğitim ve (b) test veri setleri için tibia plato kırığı tespit Hassasiyet (SEN) ve Negatif tahmin oranı (FDR) karşılaştırması

ResNet18 mimarisi ve Ön, Yan ve Birleştirilmiş (CombF) derin öznitelikler kullanılarak DVM sınıflandırıcı ile elde edilmiş karmaşıklık matrisleri Şekil 29'da verilmiştir. Burada da görüleceği gibi birleştirilmiş öznitelikler kullanılarak hem tibia plato kırığı olan hem de tibia plato kırığı olmayan X-Ray görüntülerinin tespiti daha yüksek doğrulukla gerçekleştirilmiştir. Birleştirilmiş (CombF) özniteliklerin test veri seti için 95 kırık olan görüntüden 83'ü 102 kırık olmayan görüntüden 90'ı doğru şekilde tespit edilmiştir.







(a)



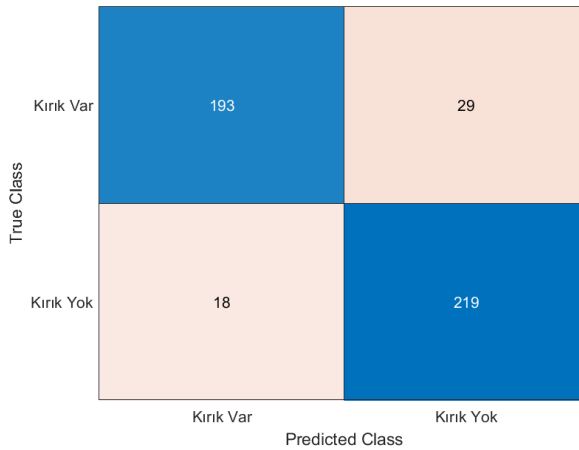
(b)




(c)



(d)



(e)



(f)

Şekil 29: ResNet18 mimarisinin (a),(c),(e) eğitim ve (b), (d),(f) test veri setleri için tibia plato kırığı tespiti karmaşıklık matrisleri. Burada (a, b) Ön, (c, d) Yan ve (e, f) Birleştirilmiş öz nitelikler kullanılarak elde edilmiştir.

5. TARTIŞMA

Tibia plato kırıkları, diz ekleminde meydana gelen ve genellikle yüksek enerjili travmalar sonucu oluşan ciddi kırıklardır. Özellikle küçük, deplase olmayan ve yalnızca tek planda görülebilen kırıkların tanısı zor olup, acil servis koşullarında hızlı değerlendirme yapılması gereken durumlarda gözden kaçabilmektedir. Bu nedenle tibia plato kırıkları, acil serviste karşılaşılan önemli bir patoloji olmakla birlikte tanı koyulması güç ve zaman zaman atlanabilen bir durumdur. Tanının atlanması veya yanlış konulması, tedavide gecikmeye ve kötü prognoz gibi ciddi klinik sonuçlara yol açabilmektedir. Özellikle sınırlı sürede çok sayıda hastanın değerlendirildiği acil servislerde, özellikli patolojilerin tanı sürecini destekleyecek ve doğru tanı oranını artıracak yöntem ve teknolojilere ihtiyaç duyulmaktadır. Bu çalışmada, yapay zeka destekli algoritmaların tibia plato kırığı tanısındaki etkinliği araştırılmıştır. Bulgularımız, farklı derin öğrenme mimarileri kullanılarak geliştirilen yapay zeka modellerinin %90 ve üzeri doğruluk oranlarıyla kırık tespitinde başarılı olduğunu göstermektedir. Özellikle anterior-posterior (AP) ve lateral görüntülerin görüntü aşamasında birleştirilerek sisteme tanıtıldığı yöntemde, hem yüksek doğruluk (%93.90), hem yüksek duyarlılık (%89.60) hem de düşük FDR (%2.30) değerleri elde edilmiştir. Bu yönüyle ResNet18 mimarisi, çalışmada kullanılan veri seti için en başarılı model olmuş ve klinik uygulamalarda tercih edilebilir bir çözüm olarak öne çıkmıştır.

Yakın zamanda Liu ve arkadaşları, ortopedi hekimlerinin tibia plato kırıklarını teşhis etme sürecini desteklemek amacıyla yeni bir yapay zeka algoritması geliştirmiştir. Bu çalışmada, radyografiler üzerinde tibia plato kırığı tanısını kolaylaştırmak üzere RetinaNet tabanlı bir algoritma tasarlanmıştır (69). Söz konusu algoritma %91 doğruluk oranı göstermiştir. İnsan performansı ile karşılaştırıldığında (doğruluk oranı: %92 ± 0.03), yapay zekanın tibia plato kırığı tanısında benzer düzeyde doğruluk sergilediği görülmüştür. Bizim çalışmamızda da kullanılan farklı mimariler benzer doğruluk oranları elde etmemizi sağlamıştır. Ancak Liu ve arkadaşlarının çalışmasında yalnızca tek yönlü radyografiler üzerinden değerlendirme yapılmıştır. Buna karşın, bizim çalışmamızda hem önden hem de yandan çekilmiş iki yönlü radyografiler kullanılarak, klinik pratikteki değerlendirme süreci daha gerçekçi biçimde modellenmiştir. Bu yönüyle çalışmamız tasarım açısından daha avantajlı görünmektedir; zira günlük klinik uygulamalarda yalnızca tek yönlü görüntüler üzerinden yapılan değerlendirmeler tanı hatası riskini artırabilmektedir. Tüm bunlara rağmen benzer doğruluk oranlarının elde edilmesi ve

hekim performansına yakın sonuçların yakalanması, yapay zeka destekli algoritmaların tibia plato kırığı tanısında güvenle kullanılabilceğini göstermektedir. Öte yandan, kırıkların sınıflandırılması konusunda yapay zekanın klinik uygulanabilirliği henüz netlik kazanmamıştır. Mohammadi ve arkadaşlarının yaptığı çalışmada, Tibia plato kırıklarının ChatGPT-4o tarafından doğru şekilde tanınıp tanınmayacağı araştırılmış ve elde edilen sonuçlar bir acil servis hekimi ile bir radyoloğun değerlendirmeleriyle karşılaştırılmıştır (70). Çalışma sonuçları, yapay zeka dil modelinin doktorlara yakın doğrulukla tanı koyabileceğini belirtmiştir. Ancak, bu modelin dışlama amacıyla kullanılmayacağı vurgulanmıştır. Gaast ve arkadaşları tarafından yapılan çalışmada, tibia plato kırıklarının tespiti ve sınıflandırılmasında derin öğrenme modellerinin kullanımı incelenmiş; yapay zeka algoritmalarının kırık tespitinde etkili olduğu, ancak kırıkların sınıflandırılması konusunda yeterli başarı gösteremediği bildirilmiştir (71). Söz konusu çalışmada, kırık tanısında GoogleNet algoritmasının ResNet algoritmasına kıyasla daha yüksek doğruluk sağladığı; duyarlılık değerinin (%92,7'ye karşı %82,9) daha yüksek, genel doğruluk oranının ise orta düzeyde (%70,4'e karşı %65,4) olduğu rapor edilmiştir. Ancak, çalışmada hangi ResNet mimari modelinin kullanıldığı belirtilmemiştir. Ayrıca, AP ve lateral graflerin birleştirilip birleştirilmediği de net olarak açıklanmamıştır. Bu çalışmadan farklı olarak, bizim araştırmamızda kullanılan ResNet mimarileri %90'ın üzerinde duyarlılık (sensitivite) değerlerine ulaşmıştır. Literatürde tibia plato kırıklarının tespitine yönelik yapay zeka algoritmalarının kullanıldığı mevcut çalışmalar ile elde ettiğimiz sonuçlar genel olarak benzerlik göstermektedir. Özellikle ResNet temelli mimariler, kırık tespitinde kullanılabilirliği yüksek bir model olarak öne çıkmaktadır.

Çalışmamızda, farklı derin öğrenme mimarilerinin değişken doğruluk oranları gösterdiği gözlemlenmiştir. Bu kapsamda, 'Görüntü Aşamasında Birleştirme' ve 'Öznitelik Aşamasında Birleştirme' olmak üzere iki farklı yaklaşımda beş farklı mimari model değerlendirilmiştir. Elde edilen dikkat çekici bulgulardan biri, görüntü aşamasında birleştirme yöntemiyle uygulanan yapay zeka algoritmalarının, öznitelik aşamasındaki birleştirmeye kıyasla daha yüksek doğruluk oranları sağlamasıdır. Bu doğrultuda, ileride yapılacak çalışmalarda iki yönlü grafler üzerinden kemik kırıklarının değerlendirilmesinde görüntü aşamasında birleştirme yönteminin tercih edilmesi daha uygun görünmektedir. Ayrıca, değerlendirilen beş mimari arasında ResNet18; yüksek doğruluk, duyarlılık ve özgüllük oranlarının yanı sıra hızlı eğitilebilirliği, düşük maliyeti ve gerçek zamanlı uygulamalar için uygun olması sebebiyle ön plana çıkmaktadır. Elde

edilen bulgular doğrultusunda, kırık tespiti süreçlerinde ResNet18 mimarisinin tercih edilmesi önerilmektedir.

Ortopedik hastalıkların tespitine yönelik benzer çalışmalar literatürde yer almaktadır. Bu çalışmada ele alınan TPK gibi, distal radius kırıkları (DRK) da sık karşılaşılan ortopedik yaralanmalar arasında yer almakta ve doğru, hızlı tanı koymak zaman zaman güç olabilmektedir. Bu kapsamda Gan ve arkadaşları, X-ray görüntülerinde DRK tespitini değerlendirmek amacıyla bir CNN algoritması geliştirmiştir. (72). Araştırmada geliştirilen modelin, ortopedi uzmanlarıyla benzer doğruluk oranlarına ulaştığı ve genişletilmiş klinik uygulamalarda destekleyici bir araç olarak kullanılabileceği ifade edilmiştir. Benzer şekilde, Lindsey ve arkadaşları tarafından gerçekleştirilen bir çalışmada, büyük ölçekli bir DRK veri setiyle eğitilen CNN modeli, derin öğrenme süreci sonunda ortopedi uzmanlarına kıyasla daha yüksek bir doğruluk oranı sergilemiştir. (73). Ayrıca, duyarlılık ve özgüllük değerlerinde anlamlı artış sağlandığı ve bu sayede DRK tanısında gözden kaçan ya da yanlış tanı alan vakaların belirgin şekilde azaltıldığı gösterilmiştir.

Humerus suprakondiler kırıklarının (HSK) tespitine yönelik olarak Choi ve arkadaşları tarafından yürütülen bir başka çalışmada, geniş bir hasta popülasyonunu kapsayan beş yıllık veriler kullanılarak bir yapay zeka ağı geliştirilmiştir (74). Elde edilen sonuçlara göre, eğitilen algoritma HSK tanısında yüksek düzeyde duyarlılık göstermiş ve klinik ortamlarda hızlı teşhis süreçlerine anlamlı katkılar sunabileceği ortaya konmuştur. Öte yandan, proksimal humerus kırıklarının (PHK) tanısına yönelik olarak Chung ve arkadaşları tarafından gerçekleştirilen çalışmada, dört farklı PHK alt tipinin yapay zeka modeli aracılığıyla analiz edildiği bildirilmiştir (75). Çalışma sonuçları, yapay zeka tabanlı algoritmanın PHK tespitinde etkili bir yöntem sunduğunu ve aynı zamanda Neer sınıflamasının doğruluğunu artırma potansiyeline sahip olduğunu ortaya koymuştur. Bu bulgular, PHK'nın daha isabetli şekilde sınıflandırılmasını sağlayarak klinik karar verme süreçlerine olumlu katkılar sunabileceğini göstermektedir.

Önceki çalışmalarda, yapay zeka uygulamalarının acil servislerde tanı ve değerlendirme süreçlerinde etkin bir şekilde kullanılabileceği bildirilmiştir. Özellikle çeşitli abdominopelvik patolojilerin değerlendirilmesinde yapay zeka destekli algoritmaların uygulanabilirliğini ortaya koyan çalışmalar literatürde yer almaktadır (76) (77). Zhou ve arkadaşları tarafından gerçekleştirilen çalışmada, ileus tanısında yapay zeka algoritmalarının etkin bir şekilde kullanılabileceği bildirilmiştir (78). Mastrodicasa ve

arkadaşları tarafından yapılan bir derlemede, aort diseksiyonu tanısında yapay zeka algoritmalarının kullanılabilir olduğu belirtilmiş ve bu alanda daha fazla çalışmaya ihtiyaç duyulduğu vurgulanmıştır (79). Salman ve arkadaşlarının yaptığı çalışmada, yapay zeka algoritmalarının subaraknoid kanama tanısında bakım süreçlerini hızlandırma açısından önemli bir potansiyele sahip olduğu ifade edilmiştir (80). Görüldüğü üzere, yalnızca kemik kırıkları değil, acil servisi ilgilendiren pek çok farklı patolojide de yapay zeka ve derin öğrenme algoritmaları tanı koyma ve hastalık yönetim süreçlerinde etkili bir destek aracı olarak öne çıkmaktadır.

5.1. Kısıtlılıklar

Bu çalışmanın belirli sınırlamaları bulunmaktadır. İlk olarak, kullanılan veri setinin görece küçük olması, algoritmanın genel performansını ve genellebilirliğini sınırlayabilecek bir faktördür. Makine öğrenme modellerinin daha güvenilir hale gelmesi ve farklı hasta popülasyonları üzerinde tutarlı sonuçlar vermesi için daha geniş ve çeşitli veri setleriyle eğitilmesi gerekmektedir. Bu nedenle, ilerleyen araştırmalarda daha büyük ve heterojen hasta gruplarını içeren bir veri tabanı oluşturulması, algoritmanın doğruluk ve güvenilirlik açısından optimize edilmesine katkı sağlayacaktır.

Mevcut yapay zeka modeli, tibia plato kırıklarının tanınması açısından umut verici sonuçlar vermesine rağmen, modelin performansını daha da ileriye taşıyacak bazı iyileştirmelere ihtiyaç duyulmaktadır. Özellikle, algoritmanın karar mekanizması üzerinde yapılacak optimizasyonlarla daha kompleks kırık tiplerinin sınıflandırılması sağlanabilir. Bu noktada, kırık morfolojisinin daha iyi analiz edilmesi ve kırık hattının tespitinin ötesine geçilerek kırık tiplerinin sistematik bir şekilde sınıflandırılması, klinik yönetim açısından kritik bir rol oynayacaktır. Çünkü kırık sınıflaması, uygun tedavi seçiminin belirlenmesi ve cerrahi yöntemin planlamanın açısından büyük önem taşımaktadır. Bu bağlamda, gelecekteki çalışmalar algoritmayı sadece kırık tespitine değil, aynı zamanda AO veya Schatzker gibi klinik olarak kabul gören sınıflama sistemlerine entegre olacak şekilde geliştirmesi hedeflenmelidir.

Son olarak, yapay zeka tabanlı tanı sistemlerinin klinik ortamdaki gerçek dünya koşullarında uygulanabilirliği açısından daha fazla doğrulama ve çok merkezli çalışmalar gerekmektedir. Modelin performansı, mevcut çalışma kapsamında acil olmayan koşullarda değerlendirilmiş olup, acil servis ortamında yüksek zaman baskısı ve değişken hasta profilleri altında nasıl bir performans sergileyeceği tam olarak bilinmemektedir. Ek olarak, yapay zeka destekli klinik karar destek sistemlerinin kullanımı ile ortaya

ıkabilecek olası hataların tıbbi ve hukuki sorumluluęunun nasıl belirleneceęi konusunda mevcut dzenlemeler henz netlik kazanmamıřtır. Ancak, bu tr yasal ve etik belirsizlikler, yapay zeka teknolojilerinin klinik tanı srelerinde kullanımını kısıtlamamalıdır. Aksine, yapay zeka tabanlı modellerin gvenilirlięini artırmaya ynelik ileri alıřmaların teřvik edilmesi ve bu sistemlerin gvenli bir řekilde entegrasyonunu saęlayacak dzenlemelerin oluřturulması gerekmektedir.



6. SONUÇ VE ÖNERİLER

Yapay zeka algoritmaları ve derin öğrenme modelleri acil servisin önemli ve güç tanı konulan patolojilerinden bir tanesi olan tibia plato kırıklarının tanısında kullanılabilir bir destek sistemi sunmaktadır. Çalışmamızın sonuçları ResNet18 mimari modelleme sistemi kullanılmasının daha uygun olduğu sonucuna varmıştır. Acil servis gibi yoğun ve hızlı tanı konulması gereken ortamlarda tibia plato kırıklarının tespitinde yapay zeka algoritmalarının ve özellikle de ResNet18 mimari modellemesinin kullanılmasını öneriyoruz.



7. KAYNAKLAR

1. **Millar, S., Bennett, K., Fraysse, F. et al.** (2020). Longitudinal changes in lower limb joint loading up to two years following tibial plateau fracture.. *Gait & posture*, 78, 72-79 . <https://doi.org/10.1016/j.gaitpost.2020.03.008>.
2. **Doornberg, J., Rademakers, M., Bekerom, M. et al.** (2011). Two-dimensional and three-dimensional computed tomography for the classification and characterisation of tibial plateau fractures.. *Injury*, 42 12, 1416-25 . <https://doi.org/10.1016/j.injury.2011.03.025>.
3. **Barragán-Montero, A., Javaid, U., Valdes, G. et al.** Artificial intelligence and machine learning for medical imaging: A technology review. *Physica medica*, 83, 242-256 . <https://doi.org/10.1016/j.ejmp.2021.04.016>.
4. **Tanzi, L., Vezzetti, E., Moreno, R. et al.** (2020). Hierarchical fracture classification of proximal femur X-ray images using a multistage Deep Learning approach.. *European journal of radiology*, 133, 109373 . <https://doi.org/10.1016/j.ejrad.2020.109373>.
5. **Lex, J., Di Michele, J., Koucheqi, R. et al.** (2023). Artificial Intelligence for Hip Fracture Detection and Outcome Prediction. *JAMA Network Open*, 6. <https://doi.org/10.1001/jamanetworkopen.2023.3391>.
6. **Willinger, L., Athwal, K., Holthof, S. et al.** (2023). Role of the Anterior Cruciate Ligament, Anterolateral Complex, and Lateral Meniscus Posterior Root in Anterolateral Rotatory Knee Instability: A Biomechanical Study. *The American Journal of Sports Medicine*, 51, 1136 - 1145. <https://doi.org/10.1177>.
7. **DeFrate, L., Sun, H., Gill, T. et al.** (2004). In vivo tibiofemoral contact analysis using 3D MRI-based knee models.. *Journal of biomechanics*, 37 10, 1499-504 . <https://doi.org/10.1016/J.JBIOMECH.2004.01.012>.
8. **Kimura, Y., Ishibashi, Y., & Tsuda, E.** (2019). Anterior Cruciate Ligament Injury. *The Japanese Journal of Rehabilitation Medicine*. <https://doi.org/10.2490/jjrmc.56.784>.
9. **Patel, J., & Khan, W.** (2020). Collateral Ligament Injuries in the Knee. , 375-384. https://doi.org/10.1007/978-3-030-43286-7_23.
10. **Kugelman, D., Qatu, A., Strauss, E. et al.** (2018). Knee Stiffness After Tibial Plateau Fractures: Predictors and Outcomes (OTA-41). *Journal of Orthopaedic Trauma*, 32, e421–e427. <https://doi.org/10.1097/BOT.0000000000001304>.
11. **Manidakis, N., Dosani, A., Dimitriou, R. et al.** (2010). Tibial plateau fractures: functional outcome and incidence of osteoarthritis in 125 cases. *International Orthopaedics*, 34, 565-570. <https://doi.org/10.1007/s00264-009-0790-5>.
12. **Gahr, P., Kopf, S., & Pauly, S. et al.** (2023). Current concepts review: Management of proximal tibial fractures. *Frontiers in Surgery*, 10. <https://doi.org/10.3389/fsurg.2023.1138274>.
13. **Gicquel, T., Najihi, N., Vendevre, T. et al.** (2013). Fractures du plateau tibial: Reproductibilité de trois classifications (Schatzker, AO, Duparc) et révision de la classification de Duparc. *Revue de Chirurgie Orthopédique et Traumatologique*, 99(7), 668-679.
14. **Erdman, M., Gibbs, S., Tucker, D. et al.** (2021). Radiographic detection of lateral plateau involvement in medial tibial plateau fractures (AO/OTA 41-B1.2, 1.3, 3.2 and 3.3). *European Journal of Orthopaedic Surgery & Traumatology*, 32, 1501 - 1508. <https://doi.org/10.1007/s00590-021-03117-7>.
15. **Molenaars, R., Mellema, J., Doornberg, J. et al.** (2015). Tibial Plateau Fracture Characteristics: Computed Tomography Mapping of Lateral, Medial, and Bicondylar Fractures.. *The Journal of bone and joint surgery. American volume*, 97 18, 1512-20 . <https://doi.org/10.2106/JBJS.N.00866>.

16. **Phelan, N., Rowland, P., Galvin, R. et al.** (2016). A systematic review and meta-analysis of the diagnostic accuracy of MRI for suspected ACL and meniscal tears of the knee. *Knee Surgery, Sports Traumatology, Arthroscopy*, 24, 1525-1539. <https://doi.org/10.1007/s00167-015-3861-8>.
17. **Mthethwa, J., & Chikate, A.** (2018). A review of the management of tibial plateau fractures. *MUSCULOSKELETAL SURGERY*, 102, 119-127. <https://doi.org/10.1007/s12306-017-0514-8>.
18. **Rijal, A., & Rajthala, A.** (2020). Functional outcome of tibial plateau fracture managed conservatively. *International Journal of Research in Orthopaedics*, 6, 447-450. <https://doi.org/10.18203/issn.2455-4510.intjresorthop20201721>.
19. **Chang, S., Hu, S., Zhang, Y. et al.** (2014). A surgical protocol for bicondylar four-quadrant tibial plateau fractures. *International Orthopaedics*, 38, 2559-2564. <https://doi.org/10.1007/s00264-014-2487-7>.
20. **Metcalfe, D., Hickson, C., McKee, L. et al.** (2015). External versus internal fixation for bicondylar tibial plateau fractures: systematic review and meta-analysis. *Journal of Orthopaedics and Traumatology : Official Journal of the Italian Society of Orthopaedics and Traumatology*, 16, 275 - 285. <https://doi.org/10.1007/s00264-014-2487-7>.
21. **Tripathy, S., Varghese, P., Panigrahi, S. et al.** (2021). External fixation versus open reduction and internal fixation in the treatment of Complex Tibial Plateau Fractures: A systematic review and meta-analysis.. *Acta orthopaedica et traumatologica turcica*, 55 5, 444-456 . <https://doi.org/10.5152/j.aott>.
22. **Jabara, J., Only, A., Paull, T. et al.** (2022). Arthroscopically Assisted Percutaneous Screw Fixation of Tibial Plateau Fractures.. *JBJS essential surgical techniques*, 12 2. <https://doi.org/10.2106/jbjs.st.21.00026>.
23. **Henry, P., Wasserstein, D., Paterson, M. et al.** (2015). Risk Factors for Reoperation and Mortality After the Operative Treatment of Tibial Plateau Fractures in Ontario, 1996–2009. *Journal of Orthopaedic Trauma*, 29, 182–188. <https://doi.org/10.1097/BOT.0000000000000237>.
24. **Yuwen, P., Lv, H., Chen, W. et al.** (2018). Age-, gender- and Arbeitsgemeinschaft für Osteosynthesefragen type-specific clinical characters of adult tibial plateau fractures in eighty three hospitals in China. *International Orthopaedics*, 42, 667-672. <https://doi.org/10.1007/s00264-018-3769->.
25. **Hap, D., & Kwek, E.** (2020). Functional outcomes after surgical treatment of tibial plateau fractures.. *Journal of clinical orthopaedics and trauma*, 11 Suppl 1, S11-S15 . <https://doi.org/10.1016/J.JCOT.2019.04.007>.
26. **Jiang, F., Jiang, Y., Zhi, H. et al.** (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology*, 2, 230 - 243. <https://doi.org/10.1136/svn-2017-000101>.
27. **Lee, D., & Yoon, S.** (2021). Application of Artificial Intelligence-Based Technologies in the Healthcare Industry: Opportunities and Challenges. *International Journal of Environmental Research and Public Health*, 18. <https://doi.org/10.3390/ijerph18010271>.
28. **Schneider, D.** (2020). Machine Learning and Artificial Intelligence. *Health Services Research*. https://doi.org/10.1007/978-3-030-28357-5_14.
29. **Shamout, F., Zhu, T., & Clifton, D.** (2020). Machine Learning for Clinical Outcome Prediction. *IEEE Reviews in Biomedical Engineering*, 14, 116-126. <https://doi.org/10.1109/RBME.2020.3007816>.
30. **Park, S., Yeo, N., Kang, S. et al.** (2024). Early Prediction of Mortality for Septic Patients Visiting Emergency Room Based on Explainable Machine Learning: A Real-World Multicenter Study. *Journal of Korean Medical Science*, 39. <https://doi.org/10.3346/jkms.2024.39.e53>.
31. **Jiang, T., Gradus, J., & Rosellini, A.** (2020). Supervised Machine Learning: A Brief Primer.. *Behavior therapy*, 51 5, 675-687 . <https://doi.org/10.1016/j.beth.2020.05.002>.

32. **Abukmeil, M., Ferrari, S., Genovese, A. et al.** (2021). A Survey of Unsupervised Generative Models for Exploratory Data Analysis and Representation Learning. *ACM Computing Surveys (CSUR)*, 54, 1 - 40. <https://doi.org/10.1145/3450963>.
33. **Bing, Z., Lerch, D., Huang, K. et al.** (2022). Meta-Reinforcement Learning in Non-Stationary and Dynamic Environments. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45, 3476-3491. <https://doi.org/10.1109/TPAMI.2022.3185549>.
34. **Awad, M., & Khanna, R.** (2015). Support Vector Machines for Classification. , 39-66. https://doi.org/10.1007/978-1-4302-5990-9_3.
35. **Pizarro, R., Cheng, X., Barnett, A. et al.** (2016). Automated Quality Assessment of Structural Magnetic Resonance Brain Images Based on a Supervised Machine Learning Algorithm. *Frontiers in Neuroinformatics*, 10. <https://doi.org/10.3389/fninf.2016.00052>.
36. **Islam, M., Chen, G., & Jin, S.** (2019). An Overview of Neural Network. *American Journal of Neural Networks and Applications*. <https://doi.org/10.11648/J.AJNNA.20190501.12>.
37. **Shahid, N., Rappon, T., & Berta, W.** (2019). Applications of artificial neural networks in health care organizational decision-making: A scoping review. *PLoS ONE*, 14. <https://doi.org/10.1371/journal.pone.0212356>.
38. **Sharma, S., Sharma, S., & Athaiya, A.** (2020). ACTIVATION FUNCTIONS IN NEURAL NETWORKS. *International Journal of Engineering Applied Sciences and Technology*. <https://doi.org/10.33564/ijeast.2020.v04i12.054>.
39. **Ozkaya, E., Topal, F. E., Bulut, T. et al.** (2022). Evaluation of an artificial intelligence system for diagnosing scaphoid fracture on direct radiography. *European Journal of Trauma and Emergency Surgery*, 1-8. <https://doi.org/10.1007/s00068-022-01886-0>.
40. **Shrestha, A., & Mahmood, A.** (2019). Review of Deep Learning Algorithms and Architectures. *IEEE Access*, 7, 53040-53065. <https://doi.org/10.1109/ACCESS.2019.2912200>.
41. **Ojha, V., Abraham, A., & Snášel, V.** (2017). Metaheuristic design of feedforward neural networks: A review of two decades of research. *Eng. Appl. Artif. Intell.*, 60, 97-116. <https://doi.org/10.1016/j.engappai.2017.01.013>.
42. **Shewalkar, A., Nyavanandi, D., & Ludwig, S.** (2019). Performance Evaluation of Deep Neural Networks Applied to Speech Recognition: RNN, LSTM and GRU. *Journal of Artificial Intelligence and Soft Computing Research*, 9, 235 - 245. <https://doi.org/10.2478/jaiscr-2019-0006>.
43. **Alaloul, W., & Qureshi, A.** (2020). Data Processing Using Artificial Neural Networks. *Dynamic Data Assimilation - Beating the Uncertainties*. <https://doi.org/10.5772/intechopen.91935>.
44. **He, K., Wang, C., He, Y. et al.** (2023). Artificial Neuron Devices.. *Chemical reviews*. <https://doi.org/10.1021/acs.chemrev.3c00527>.
45. **Masood, A., Sheng, B., Li, P. et al.** (2018). Computer-Assisted Decision Support System in Pulmonary Cancer detection and stage classification on CT images. *Journal of biomedical informatics*, 79, 117-128 . <https://doi.org/10.1016/j.jbi.2018.01.005>.
46. **Miotto, R., Wang, F., Wang, S. et al.** (2018). Deep learning for healthcare: review, opportunities and challenges. *Briefings in bioinformatics*, 19 6, 1236-1246 . <https://doi.org/10.1093/bib/bbx044>.
47. **Chen, L., Li, S., Bai, Q. et al.** (2021). Review of Image Classification Algorithms Based on Convolutional Neural Networks. *Remote. Sens.*, 13, 4712. <https://doi.org/10.3390/rs13224712>.

48. **Manimegalai, P., Suresh Kumar, R., Valsalan, P. et al.** (2022). 3D Convolutional Neural Network Framework with Deep Learning for Nuclear Medicine. *Scanning*, 2022, 9640177. <https://doi.org/10.1155/2022/9640177> (Retraction published *Scanning*. 2023 Dec 13;2023:9765894. doi: 10.1155/2023/9765894.).
49. **Yu, H., Yang, L., Zhang, Q. et al.** (2021). Convolutional neural networks for medical image analysis: State-of-the-art, comparisons, improvement and perspectives. *Neurocomputing*, 444, 92-110. <https://doi.org/10.1016/J.NEUCOM.2020.04.157>.
50. **Salehi, A., Khan, S., Gupta, G. et al.** (2023). A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope. *Sustainability*. <https://doi.org/10.3390/su15075930>.
51. **Saleem, M., Senan, N., Wahid, F. et al.** (2022). Comparative Analysis of Recent Architecture of Convolutional Neural Network. *Mathematical Problems in Engineering*. <https://doi.org/10.1155/2022/7313612>.
52. **Guo, Y., Liu, Y., Oerlemans, A. et al.** (2016). Deep learning for visual understanding: A review. *Neurocomputing: An International Journal*, 187, 27–48. <https://doi.org/10.1016/j.neucom.2015.09.116>.
53. **Sun, M., Song, Z., Jiang, X. et al.** (2017). Learning Pooling for Convolutional Neural Network. *Neurocomputing*, 224, 96-104. <https://doi.org/10.1016/j.neucom.2016.10.049>.
54. **Basha, S., Dubey, S., Pulabaigari, V. et al.** (2019). Impact of Fully Connected Layers on Performance of Convolutional Neural Networks for Image Classification. *Neurocomputing*, 378, 112-119. <https://doi.org/10.1016/j.neucom.2019.10.008>.
55. **Li, H., Li, J., Guan, X. et al.** (2019). Research on Overfitting of Deep Learning. 2019 15th International Conference on Computational Intelligence and Security (CIS), 78-81. <https://doi.org/10.1109/CIS.2019.00025>.
56. **Justus, D., Brennan, J., Bonner, S. et al.** (2018). Predicting the Computational Cost of Deep Learning Models. 2018 IEEE International Conference on Big Data (Big Data), 3873-3882. <https://doi.org/10.1109/BigData.2018.8622396>.
57. **Hu, Z., Zhang, J., & Ge, Y.** (2021). Handling Vanishing Gradient Problem Using Artificial Derivative. *IEEE Access*, 9, 22371-22377. <https://doi.org/10.1109/ACCESS.2021.3054915>.
58. **Bai, C., Huang, L., Pan, X. et al.** (2018). Optimization of deep convolutional neural network for large scale image retrieval. *Neurocomputing*, 303, 60-67. <https://doi.org/10.1016/j.neucom.2018.04.034>.
59. **Alruwaili, M., Alanazi, S., Abd El-Ghany, S. et al.** (2019). An efficient deep learning model for olive diseases detection. *International Journal of Advanced Computer Science and Applications*, 10(8), Article 863. <https://doi.org/10.14569/IJACSA.2019.0100863>.
60. **Balduzzi, D., Frean, M., Leary, L. et al.** (2017). The Shattered Gradients Problem: If resnets are the answer, then what is the question?. *ArXiv*, abs/1702.08591.
61. **Buvaneswari, P., & Gayathri, R.** (2021). Deep Learning-Based Segmentation in Classification of Alzheimer's Disease. *Arabian Journal for Science and Engineering*, 46, 5373 - 5383. <https://doi.org/10.1007/s13369-020-05193-z>.
62. **Brown, J., Gharineiat, Z., & Raj, N.** (2022). CNN-based image classification of malicious UAVs. *Applied Sciences*, 13(1), 240. <https://doi.org/10.3390/app13010240>.
63. **Suresh, B., Pillai, K., Kalsi, G. et al.** (2021). Early prediction of DNN activation using hierarchical computations. *Mathematics*, 9(23), 3130.

64. **Kalshetty, R., & Parveen, A.** (2023). Abnormal event detection model using an improved ResNet101 in context-aware surveillance system. *Cognitive Computation and Systems*, 5, Article e12084. <https://doi.org/10.1049/ccs2.12084>.
65. **Sinha, D., & El-Sharkawy, M.** (2019). Thin MobileNet: An Enhanced MobileNet Architecture. 2019 IEEE 10th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON), 0280-0285. <https://doi.org/10.1109/UEMCON47517.2019.8993089>.
66. **Turk, V., Çatal, H., & Kaya, S.** (2022). Automatic prediction of COVID-19 from chest-computed tomography (CT) images using deep learning architectures. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. <https://doi.org/10.17714/gumusfenbil.1002738>.
67. **Kumar, M., Hasmitha, D., Usha, B. et al.** (2024). Brain Tumor Classification Using MobileNet. 2024 International Conference on Integrated Circuits and Communication Systems (ICICACS), 1-7. <https://doi.org/10.1109/ICICACS60521.2024.10499117>.
68. **Marullo, G., Ulrich, L., Antonaci, F. et al.** (2024). Classification of AO/OTA 31A/B femur fractures in X-ray images using YOLOv8 and advanced data augmentation techniques. *Bone Reports*, 101801. <https://doi.org/10.1016/j.bonr.2024.101801>.
69. **Liu, P. R., Zhang, J. Y., Xue, M. D. et al.** (2021). Artificial Intelligence to Diagnose Tibial Plateau Fractures: An Intelligent Assistant for Orthopedic Physicians. *Current medical science*, 41(6), 1158–1164. <https://doi.org/10.1007/s11596-021-2501-4>.
70. **Mohammadi, M., Parviz, S., Parvaz, P. et al.** (2025). Diagnostic performance of ChatGPT in tibial plateau fracture in knee X-ray. *Emergency radiology*, 32(1), 59–64. <https://doi.org/10.1007/s10140-024-02298-y>.
71. **van der Gaast, N., Bagave, P., Assink, N. et al.** (2025). Deep learning for tibial plateau fracture detection and classification. *The Knee*, 54, 81–89. Advance online publication. <https://doi.org/10.1016/j.knee.2025.02.001>.
72. **Gan, K., Xu, D., Lin, Y. et al.** (2019). Artificial intelligence detection of distal radius fractures: a comparison between the convolutional neural network and professional assessments. *Acta orthopaedica*, 90(4), 394–400. <https://doi.org/10.1080/17453674.2019.1600125>.
73. **Lindsey, R., Daluiski, A., Chopra, S. et al.** (2018). Deep neural network improves fracture detection by clinicians. *Proceedings of the National Academy of Sciences of the United States of America*, 115(45), 11591–11596. <https://doi.org/10.1073/pnas.1806905115>.
74. **Choi, J. W., Cho, Y. J., Lee, S. et al.** (2020). Using a Dual-Input Convolutional Neural Network for Automated Detection of Pediatric Supracondylar Fracture on Conventional Radiography. *Investigative radiology*, 55(2), 101–110. <https://doi.org/10.1097/RLI.0000000000000615>.
75. **Chung, S. W., Han, S. S., Lee, J. W. et al.** (2018). Automated detection and classification of the proximal humerus fracture by using deep learning algorithm. *Acta orthopaedica*, 89(4), 468–473. <https://doi.org/10.1080/17453674.2018.1453714>.
76. **Liu, J., Varghese, B., Taravat, F. et al.** (2022). An Extra Set of Intelligent Eyes: Application of Artificial Intelligence in Imaging of Abdominopelvic Pathologies in Emergency Radiology. *Diagnostics (Basel, Switzerland)*, 12(6), 1351. <https://doi.org/10.3390/diagnostics12061351>.
77. **Yao, J., Chu, L. C., & Patlas, M.** (2024). Applications of Artificial Intelligence in Acute Abdominal Imaging. *Canadian Association of Radiologists journal = Journal l'Association canadienne des radiologistes*, 75(4), 761–770. <https://doi.org/10.1177/08465371241250197>.

78. **Zhou, C. M., Li, H., Xue, Q. et al.** (2024). Artificial intelligence algorithms for predicting post-operative ileus after laparoscopic surgery. *Heliyon*, 10(5), e26580. <https://doi.org/10.1016/j.heliyon.2024.e26580>.

79. **Mastrodicasa, D., Codari, M., Bäumlner, K. et al.** (2022). Artificial Intelligence Applications in Aortic Dissection Imaging. *Seminars in roentgenology*, 57(4), 357–363. <https://doi.org/10.1053/j.ro.2022.07.001>.

80. **Salman, S., Gu, Q., Sharma, R. et al.** (2023). Artificial intelligence and machine learning in aneurysmal subarachnoid hemorrhage: Future promises, perils, and practicalities. *Journal of the neurological sciences*, 454, 120832. <https://doi.org/10.1016/j.jns.2023.120832>.

