



T.C. SAđLIK BİLİMLERİ ÜNİVERSİTESİ
BAđCILAR SAđLIK UYGULAMA VE ARAřTIRMA
MERKEZİ
RADYOLOJİ KLİNİđİ

DİREKT RADYOGRAFİLERDE DERİN
ÖđRENME TABANLI NESNE TANIMA
ALGORİTMASI İLE OTOMATİK FRAKTÖR TESPİTİ

Dr. Gül Gizem PAMUK



T.C. SAĐLIK BİLİMLERİ NİVERSİTESİ
BAĐCILAR SAĐLIK UYGULAMA VE ARAřTIRMA
MERKEZİ
RADYOLOJİ KLİNİĐİ

DİREKT GRAFİLERDE DERİN ĐRENME
TABANLI NESNE TANIMA ALGORİTMASI İLE
OTOMATİK FRAKTR TESPİTİ

Dr. Gl Gizem PAMUK

Tez Danıřmanı: Prof. Dr. Ahmet Tan CİMİLLİ

(TIPTA UZMANLIK TEZİ)

İSTANBUL

MAYIS 2023

ÖNSÖZ

Uzmanlık eğitimim süresince bilgi ve deneyimleri ile beni yönlendirerek bu zorlu süreci kolaylaştıran, mesleki tecrübelerinden her zaman yararlandığım tez danışmanlığımı üstlenen saygıdeğer hocam Prof. Dr. Ahmet Tan CİMİLLİ'ye minnet ve saygı ile teşekkür ederim.

Beraber çalışmaktan onur duyduğum, sonsuz bilgi, görgü ve deneyimlerini benimle paylaşarak gelişimime büyük katkı sağlayan, prensipli ve dürüst kişiliğine hayran olduğum, bana araştırma becerisi kazandıran değerli ablam ve klinik şefimiz Uzm. Dr. Candan VARLIK'a teşekkür ederim.

Eğitimimde haklarını ödeyemeceğim kadar büyük emekleri olan, hem hayat hem de mesleki bilgilerinden sonsuz yararlandığım, yorucu ve zorlu uzmanlık eğitimimi keyifli hale getiren, yanlarında hep huzurlu hissettiğim, bana bu kiliniği aile ortamı tadında sevdiren sevgili uzmanlarım, ablalarım, Uzm. Dr. Öznur Funda Gelengeç, Uzm. Dr. Esra BİLGİ, Uzm. Dr. Deniz EKİNCİ, Uzm. Dr. Emine BALKAN, Uzm. Dr. Ebru SARIKAYA'ya yürekten teşekkür ederim.

Öğrenimimize büyük katkı sağlayan, bizleri her konuda destekleyen, bildiği ve tecrübe ettiği her vakayı aktarmaya çalışan, akademik olarak en iyi yerlerde olacağı şüphesiz değerli başasistanımız Uzm. Dr. Musa ATAY'a teşekkür ederim.

Radyoloji eğitimimin ilk gününden itibaren sabırla her soruma cevap veren, gördükleri her yeni bilgiyi benimle paylaşan, yeri geldiğinde gece nöbetlerimde uykularından uyanarak benimle birlikte vaka çözümleyen kıdemlilerim, arkadaşlarım Dr.Mehmet Karagülle, Dr. Süleyman Öncü, Dr. Samet Şimşek'e ve ablalarım Dr. Tuğba Polat ve Dr. Çilem KOLCA'ya teşekkürlerimi sunarım.

Tezimin derin öğrenme alt yapısını kendisi kod yazarak oluşturan, yapay zekanın radyolog hali, her dakikasını öğrenerek en verimli değerlendirmeyi bilen, en iyi yerlerde olmayı hak eden, eğlenceli kişiliğini takdir ettiğim ve birlikte çalışmaktan mutluluk duyduğum arkadaşım Dr. Murat Yüce'ye sonsuz teşekkür ederim.

Birlikte çalışmaktan mutluluk duyduğum, en zor zamanlarda her zaman birbirimize destek olduğumuz çalışma arkadaşlarım Dr. Samet Öztürk ve Dr. Edip İşleyen'e ve kliniğimize yeni katılan tüm genç asistan arkadaşlarıma teşekkür ederim.

Bir süre beraber çalışma fırsatı bulduğumuz, engin bilgilerinden bizleri eksik etmeyen, eğitimimize katkı sağlayan sayın Doç. Dr. İsmail Şerifoğlu'na minnetle teşekkür ederim.

Beraber çalıştığım tüm personel, raportör, sekreter arkadaşlarıma şükranlarımı sunuyorum.

Eğitime her zaman en büyük destek ve değeri veren, kendisi istediği eğitimi almasına da üç çocuğunun da tıp doktoru olmasına büyük katkı sağlayan, onları en güzel şekilde eğitip yönlendiren, hayatımın her anında sevgi ve şefkatini hissettiğim canım annem Nejla KAYA'ya, evlatları için elinden gelenin en iyisini, en güzelini kendini unutma ve yorma pahasına yapan canım babam Nuri KAYA'ya, her durumda bana destek olacağını bildiğim ve gücünü arkamda hissettiğim, koca yürekli canım abim Emin Erdem KAYA'ya, dünyaya gelmeden önce bile aynı alanı paylaşmaktan mutluluk duyduğum ve beraber daha uzun süreler boyunca ortak alanları paylaşmak istediğim çok sevdiğim ikizim Mustafa Görkem KAYA'ya bu günlerle gelmemdeki katkılarından dolayı gönülden teşekkür ediyorum. Sevgi ve desteği ile her zaman yanımda olan, yoluma ışık olan ve hayatımı her alanda kolaylaştıran sevgilim, yol arkadaşım Saim PAMUK'a çok teşekkür ederim.

Dr.Gül Gizem PAMUK

İstanbul/Mayıs 2023

ÖZET

Giriş ve Amaç: Kemik fraktürleri acil servislerde çok yaygın görülen ortopedik travmatik acil sebeplerinden biridir. Travma sonrası kırık tespitinde direkt radyografi ilk başvurulması gereken tanı yöntemidir. Fakat bazı fraktürlerin direkt radyografi ile tanı konulması hem radyologlar hem de diğer branş doktorları için oldukça zorlayıcıdır. Acil servislerde yanlış tanı konulan ve bunun sonucunda hastanın zarar gördüğü durumların %41-%80'nini direkt radyografide görülen kırıkları yanlış yorumla oluşturur. İskelet yaralanmalarının, özellikle de apendiküler iskelet yaralanmalarının geç teşhis edilmesi veya gözden kaçması, radyografideki malpraktis davalarının en büyük nedenidir. Son yıllarda derin öğrenme yöntemleri kullanılarak fraktür tespit eden çalışmalar, derin öğrenme teknolojisinin fraktür tespitinde kolaylık sağlayıp yanlış yorumlama oranını belirgin azaltmada yardımcı yöntem olarak kullanılabildiğini göstermiştir. Genel olarak bu çalışmalar direkt grafileri el-el bileği- ön kol gibi tek bir bölge ile sınırlandırarak fraktür tespitinde yoğunlaşmıştır. Biz ise çalışmamızda insan vücudundaki apendiküler iskeleti içeren direkt grafilerde derin öğrenme tabanlı nesne tanıma algoritması ile otomatik fraktür tespiti yapmayı ve bu grafileri yorumlayacak olan hekimlerin duyarlılığını artırmayı, hekimlere karar destek mekanizması sağlamayı, tanı koyma süresini kısaltmayı, fraktürlerin gözden kaçmasını önleyerek yanlış/eksik tanı sonrası oluşabilecek komplikasyonları ve bunun sonucunda da hekimlerin karşılaşabileceği malpraktis davalarını önlemeyi hedefledik.

Gereç ve Yöntem: Çalışmamız retrospektif olup Bağcılar Eğitim ve Araştırma Hastanesi PACS sisteminden (Bağcılar veri seti) 4354 adet, Radiopaedia veri setinden 4632 adet olmak üzere toplam 8986 adet direkt radyografi görüntüsünü içermektedir. Görüntüler lokal bilgisayar ortamında Massachusetts Institute of Technology (MIT) lisanslı Intel®'e bağlı açık kaynak "Computer Vision Annotation Tool" (CVAT, www.cvat.ai) kullanılarak 5 yıl deneyimli bir radyolog tarafından bounding-box (sınırlayıcı kutucuk) yöntemi ile işaretlenmiştir. Veri seti işaretlenirken ilgili görüntülere anatomik lokasyonu belirtecek sınıflar atanmıştır. İşaretleme kaydedilirken YOLO işaretleme formatı tercih edilmiştir. İşaretlenmiş olan görüntülerde model eğitimi öncesinde kontrast ile sınırlandırılmış adaptif histogram eşitleme (CLAHE) ön işleme metodu uygulanmıştır. Çalışmaya dahil edilen verilerin 7678 adeti eğitim, 854 adeti validasyon, 454 adeti test veri setine ayrılmıştır. "StratifiedShuffleSplit" algoritması sayesinde eğitim, validasyon ve test veri setlerinin anatomik lokasyon ve fraktür bakımından dağılımları korunmuştur. Geliştirilecek olan modellerin genelleştirilebilirliğini

artırmak ve eğitim sürecinde model ezberlemesi olarak da ifade edilen “overfitting” i engellemek için model eğitimi esnasında “online” olarak eğitim seti üzerinde veri çoğaltımı yapılmıştır. Çalışmamızda derin öğrenme tabanlı nesne tanıma modeli olarak YOLOv7 nesne tanıma algoritması kullanılmıştır. Model eğitim süreci aktif olarak takip edilmiş olup model validasyon metriğinin (mAP50=’mean average precision’) daha fazla artış göstermediği aşamada eğitim durdurulmuş ve en yüksek mAP50 parametresine ulaşılan model test aşamasında kullanılmıştır. Validasyon aşamasında her bir kutucuk tahmini kutucuk metriklerinden sıkça kullanılan mAP50, mAP50:95, kesinlik (pozitif prediktif değer), duyarlılık hesaplamaları ile değerlendirilmiştir. Ayrıca görüntü bazlı genel pozitiflik ve negatifliğe göre kesinlik, duyarlılık, özgüllük ve f1 skorları hesaplanmıştır. Test veri setinde model tahminleri yapılmıştır. Genel radyolojide 21 yıl deneyimli (RAD2) , 6 yıl deneyimli (RAD1) ve 3 yıl deneyimli (RAD3) üç ayrı radyolog test veri setindeki görüntülerde fraktür varlığı veya yokluğu bakımından değerlendirme yapmıştır. Model başarımlarının değerlendirilmesinde mAP50, mAP50:95, kesinlik, duyarlılık metrikleri ölçülmüştür. Radyologlar arası uyum için Cohen’s Kappa değeri elde edilmiştir. Model öncesi ve sonrası radyolog performansı arasındaki farkların değerlendirilmesi için McNemar testi uygulanmıştır. Sonuçların değerlendirilmesinde $p < 0.05$ istatistiksel anlamlı kabul edilmiştir.

Bulgular: Tüm veri setinde bulunan 8986 adet direkt radyografi görüntüsünün 6283 (%69.92) tanesinde fraktür bulunmakta olup 2703 (%30) adet görüntüde fraktür bulunmamaktaydı. Tüm veri setindeki direkt radyografilerin 1881’i (%20.9) el bileği, 1442’si (%16) ayak bileği, 1108’i (%12.3) diz, 806’si (%9) ayak, 742’si (%8.3) el, 692’si (%7.7) dirsek, 562’si (%6.3) omuz, 489’u (%5.4) pelvis, 440’ı (%4.9) kruris, 407’i (%4.5) femur, 285’i (%3.2) ön kol, 105’i (%1.2) kol, 27’si (%0.3) koksofemoral direkt radyografi görüntülerinden oluşmaktadır. Otomatik nesne tanıma algoritması olarak geliştirdiğimiz YOLOv7 modelimizde validasyon aşamasında en yüksek elde edilen kesinlik değeri % 76.6, duyarlılık değeri % 52.5, güven eşik değeri 0.5 iken ortalama kesinlik (mAP@0.5) değeri % 60, güven eşik değeri 0.5-0.95 arasında iken ortalama kesinlik (mAP@0.5-0.95) değeri % 28.5 idi. Modelimizin güven eşik değeri 0.05 iken test veri setindeki F1 skoru 0.90, AUC-ROC skoru 0.89 ölçülmüştür. Güven eşik değeri 0.05 iken duyarlılık 0.91, kesinlik 0.88, özgüllük ise 0.72’dir. Test veri setindeki direkt radyografi görüntüleri genel radyolojide 6 yıl deneyimli (RAD1), 21 yıl deneyimli (RAD2) ve 3 yıl deneyimli (RAD3) radyologlar tarafından fraktür varlığı/yokluğu açısından model ile birlikte ve model desteği olmadan değerlendirilmiştir. Model ile birlikte radyolog kesinlik değeri model öncesine göre RAD1’de % 0.8, RAD2’de % 0.02, RAD3’te %

1.1 artış göstermiştir; duyarlılık değeri RAD1’de % 9, RAD2’de % 7.8, RAD3’te % 5 artış göstermiştir. Doğruluk değerleri model ile birlikte model öncesine göre RAD1’de % 5.2, RAD2’de % 7.3, RAD3’te % 11.4; F1 skoru RAD1’de % 5.8, RAD2’de % 4.7, RAD3’te % 4 artış göstermiştir. Yapılan McNemar analizinde tüm değerlendiricilerde model öncesi ve model ile birlikte değerlendirme arasında model ile birlikte değerlendirme lehine istatistiksel olarak anlamlı fark bulunmaktadır ($p<0.000$).

Sonuç: Direkt radyograflerde fraktür tespiti hekimler için oldukça zorlayıcı olabilmektedir. Direkt radyograflerde gözden kaçan veya eksik tanı alan fraktürler acil servislerdeki malpraktis davalarının en sık sebebidir. Geliştirdiğimiz derin öğrenme tabanlı nesne tanıma algoritmasının radyologların duyarlılık ve doğruluğunu arttırdığını ve tanı koyma süresini azalttığını gözlemledik. Algoritmamızın acil servislerde ve radyoloji birimlerindeki klinik pratikte uygulanarak hekimlerin fraktür tespit performansını artırabileceğini düşünüyoruz. Daha önce yapılan benzer çalışmalardan farklı olarak YOLOv7 nesne tanıma algoritmasını kullandığımız araştırma; hem çocuk hem de erişkinlerde görülebilecek apendiküler iskeletin tüm kırık çeşitlerini küçük/büyük, deplase/nondeplase, atel-fiksator-metal var/yok ayrımı yapmadan direkt radyograflerde fraktür tespiti yapan literatürdeki ilk çalışmadır.

Anahtar Kelimeler: Direkt Radyografi, Kırık, Fraktür, Nesne Tanıma, Derin Öğrenme, YOLO

ABSTRACT

Introduction and Aim: Bone fractures are one of the most common causes of orthopedic traumatic emergencies in emergency departments. Radiography (X-Ray) is the first diagnostic method to be applied in post-traumatic fracture detection. However, diagnosing some fractures by direct radiography is quite challenging for both radiologists and other doctors. Failure to identify fractures is the most common diagnostic error, which may account for 41–80% of diagnostic errors in the ED (emergency department), as a result of this, the patient is harmed. Late diagnosis or missed of skeletal injuries, particularly appendicular skeletal injuries, is a major cause of radiography malpractice suits. In recent years, studies that detect fractures using deep learning methods have shown that deep learning technology can be used as an auxiliary method in facilitating fracture detection and significantly reducing the rate of misinterpretation. These studies focused on fracture detection by limiting radiographs to a single anatomic region such as hand, wrist, forearm. In our study, we aimed to perform automatic fracture detection with a deep learning-based object detection algorithm in radiographs containing the appendicular skeleton of the human body, to increase the sensitivity of physicians who will interpret these radiographs, to provide physicians with a decision support mechanism, to shorten the diagnosis time, to prevent missed fractures and malpractice suits.

Material and methods: Our study is retrospective and includes a total of 8986 direct radiography images, consisting of 4354 images from the Bağcılar dataset obtained from Bağcılar Education and Research Hospital PACS system, and 4632 images from the Radiopaedia dataset. The images were annotated using the bounding-box method by a 5 years experienced radiologist using the Massachusetts Institute of Technology (MIT) licensed Intel® open-source "Computer Vision Annotation Tool" (CVAT, www.cvat.ai) on a local computer. Classes that indicate the anatomical location of the relevant images were assigned during the annotation of the dataset. The YOLO annotation format was preferred while saving the annotations. Adaptive histogram equalization with limited contrast (CLAHE) preprocessing method was applied to the annotated images before model training. Of the data included in the study, 7678 were splitted to the training set, 854 to the validation set, and 454 to the test set. The "StratifiedShuffleSplit" algorithm was used to maintain the distribution of anatomical location and fracture in the splitting process of training, validation, and test sets. Data augmentation was performed "online" on the training set during model training to increase the generalizability of the models and prevent overfitting during the training process. In our study,

the YOLOv7 object detection algorithm was used as a deep learning-based object detection model. The model training process was actively monitored, and the training was stopped when the model validation metric (mAP50 = 'mean average precision') showed no further improvement, and the model with the highest mAP50 parameter was used in the test phase. In the validation phase, each predicted bounding box was evaluated using common bounding box metrics such as mAP50, mAP50:95, precision (positive predictive value), and recall. Additionally, precision, recall, specificity, and f1 score were calculated based on general fracture positivity and negativity in the image. Model predictions were made on the test set, and three radiologists with 21 years of experience (RAD2), 6 years of experience (RAD1), and 3 years of experience (RAD3) evaluated the presence or absence of fractures in the images of the test set. The model performance was evaluated using mAP50, mAP50:95, precision, and recall metrics. Cohen's Kappa value was obtained for inter-radiologist agreement. McNemar test was applied to evaluate the difference between pre- and post-model reader performance. A p-value of less than 0.05 was considered statistically significant in the evaluation of the results.

Results: In the dataset, out of the 8986 direct radiography images, 6283 (69.92%) of them had fractures while 2703 (30%) did not. Among all the direct radiography images in the dataset, 1881 (20.9%) were wrist, 1442 (16%) ankle, 1108 (12.3%) knee, 806 (9%) foot, 742 (8.3%) hand, 692 (7.7%) elbow, 562 (6.3%) shoulder, 489 (5.4%) pelvis, 440 (4.9%) lower leg, 407 (4.5%) femur, 285 (3.2%) forearm, 105 (1.2%) arm, and 27 (0.3%) hip radiography images. Our YOLOv7 model, developed as an automatic object detection algorithm, achieved a maximum precision value of 76.6%, recall value of 52.5% in the validation phase. The average precision (mAP@0.5) value at the confidence threshold of 0.5 was 60%, and the average precision value at the confidence thresholds of 0.5-0.95 (mAP@0.5-0.95) was 28.5%. At the confidence threshold value of 0.05, in the test dataset, the recall was 0.91, precision was 0.88, and specificity was 0.72, the F1 score was 0.90 and the AUC-ROC score was 0.89. Direct radiography images in the test dataset were evaluated by three radiologists with 6, 21, and 3 years of general radiology experience (RAD1, RAD2, and RAD3) for the presence or absence of fractures with and without the support of the model. With the support of the model, the precision value for RAD1 increased by 0.8%, for RAD2 by 0.02%, and for RAD3 by 1.1%. The recall value increased by 9% for RAD1, 7.8% for RAD2, and 5% for RAD3. The accuracy values increased by 5.2% for RAD1, 7.3% for RAD2, and 11.4% for RAD3 with the support of the model. The F1 score increased by 5.8% for RAD1, 4.7% for RAD2, and 4% for RAD3.

The McNemar analysis showed a statistically significant difference in favor of the evaluation with the model compared to the evaluation without the model for all evaluators ($p < 0.000$).

Conclusion: Fracture detection can be quite challenging for physicians on direct radiographs. Fractures that are missed or incorrectly diagnosed on direct radiographs are the most common cause of malpractice lawsuits in emergency departments. We observed that our deep learning-based object detection algorithm increases the sensitivity and accuracy of radiologists and reduces diagnosis time. We believe that our algorithm can improve fracture detection performance for physicians in emergency departments and radiology units when applied in clinical practice. Unlike similar previous studies, our research using the YOLOv7 object detection algorithm is the first study in the literature to directly detect all types of fractures in the appendicular skeleton that can be seen in both children and adults, without distinguishing between small/large, displaced/non-displaced, and the presence/absence of splints, fixators, or metal on direct radiographs.

Keywords: Direct Radiography, Fracture, Object Detection, Deep Learning, YOLO

SİMGE VE KISALTMALAR

AHE: Adaptif Histogram Eşitleme

AP: Anteroposterior

AUC: Eğri Altındaki Alan

AUC-ROC: Alıcı İşletim Karakteristiği Eğrisi Altındaki Alan

BoF: Ücretsiz Malzemeler Çantası

BT: Bilgisayarlı Tomografi

CAD: Bilgisayar Destekli Tespit ve Teşhis

CLAHE: Kontrast Limitli Adaptif Histogram Eşitleme

CNN: Evrişimsel Sinir Ağları

COCO: Bağlamsal Ortak Nesne

CVAT: Bilgisayarlı Görüde İşaretleme Aracı

DCFPN: Genişletilmiş Evrişimli Öznitelik Piramit Ağı

DICOM: Tıpta Dijital Görüntüleme ve İletişim Standardı

E-ELAN: Genişletilmiş Verimli Katman Toplama Ağı

FAMO: Öznitelik Belirsizliği Giderme Operatörü

FCNN: Tam Evrişimli Sinir Ağları

FPN: Öznitelik Piramit Ağı

GA: Genişletilmiş Anchor

HBYS: Hastane Bilgi Yönetim Sistemi

HRCT: Yüksek Çözünürlüklü Bilgisayarlı Tomografi

JPEG: Ortak Fotoğraf Uzmanları Grubu

mAP: Ortalama Kesinlik

MCL: Medial Kollateral Ligament

MIT: Massachusetts Institute of Technology

MRG: Magnetik Rezonans Görüntüleme

MURA: Kas İskelet Radyografisi

PACS: Resim Arşivleme ve İletişim sistemi

R-CNN: Bölge Tabanlı Evrişimsel Sinir Ağları

SSD: Tek Atışlı Çoklu Kutu Detektörü

USG: Ultrasonografi

WFD: El Bileği Kırık Tespiti

WFD-C: El Bileği Kırık Tespiti Karışımı

YOLO: You Only Look Once (Sadece Bir Kez Bak)

TABLÖLAR ve ŐEKİLLER

Tablo 1. Kemiklerin Őekillerine g�re sınıflandırılması	7
Tablo 2. Salter-Harris sınıflaması tipleri.....	25
Tablo 3. Yolov7 model yapıları ve diğ�r modellere ait parametler ve COCO veri seti başarımları	42
Tablo 4. Model eđitiminde kullanılan hiperparametreler ve ilgili a�ıklamaları.....	43
Tablo 5. Veri Setlerindeki Frakt�r Olan ve Olmayan G�r�nt�lerin Sayıları	47
Tablo 6. Test setinde farklı g�ven eŐik deđerlerindeki model tahminlerinin g�r�nt� bazlı frakt�r varlıđı/yokluđu a�ısından performans metrikleri	55
Tablo 7. Model �ncesi (pre) ve model ile birlikte (post) yapılan incelemelerde radyologların performans metrikleri	58
Őekil 1. R�ntgen'in eŐi Anna Bertha Ludwig'in el radyografisi.....	3
Őekil 2. Elektromanyetik spektrum	4
Őekil 3. X-ıŐının oluŐumu.....	5
Őekil 4. Radyografik g�r�nt�de doku yođunlukları farklı olduđundan kemikler beyaza yakın, yumuŐak dokular ise gri tonları Őeklinde ortaya �ıkar.....	5
Őekil 5. Kortikal kemikteki Havers ve volkman kanalları	8
Őekil 6. Uzun kemiklerin anatomisi	10
Őekil 7. Periost ve endosteum	11
Őekil 8. �st ekstremit� anatomisi	12
Őekil 9. El iskeleti anatomisi	13
Őekil 10. Alt ekstremit� anatomisi	14
Őekil 11. Ayak iskeleti anatomisi.....	15
Őekil 12. El bileđinde olabilecek aksesuar kemikler.....	16
Őekil 13. El bileđindeki aksesuar kemiklerden os triangulare.....	16
Őekil 14. Persistan ulnar styloid	17
Őekil 15. Ayakta g�r�len bazı aksesuar kemikler	18
Őekil 16. 1. Metaparpofalengeal eklem sesamoidi.....	19
Őekil 17. Bazı frakt�r �eŐitleri g�rselleri.....	20
Őekil 18. Sırasıyla kemik frakt�r�n�n iyileŐme aŐamaları	20
Őekil 19. Stres kırığına �rnek radyografiler	21

Şekil 20. İnkomplet greenstick fraktürü.....	22
Şekil 21. Buckle (torus) fraktürü.....	23
Şekil 22. Bükülme fraktürü	23
Şekil 23. Ttuberositas tibia.....	24
Şekil 24. Çocuklarda büyüme plağı (fizis).....	25
Şekil 25. Salter-Harris sınıflaması görseli	25
Şekil 26. Çocuk ayak radyografilerinde 5. Metatars proksimalinin kemiğin şaftına paralel uzanan normal apofizi	26
Şekil 27. Nutrient foramen.....	27
Şekil 28. Cleft (yarık) epifiz.....	28
Şekil 29. Radial beak (gaga).	28
Şekil 30. Bipartite patella	29
Şekil 31. Pellegrini-Stieda lezyonu.	29
Şekil 32. Halluks sesamoid	30
Şekil 33. Makine öğrenmesi ve derin öğrenme şeması	31
Şekil 34. Nesne tanıma algoritmaların bir şekilde birden fazla nesneyi tanıyarak konumlandırmasına örnek	34
Şekil 35. Çalışma Diagramı	36
Şekil 36. Yolo işaretleme formatı	39
Şekil 37. YOLO network yapısı.....	41
Şekil 38. Bağcılar veri seti cinsiyet dağılım grafiği	45
Şekil 39. Bağcılar veri seti yaş dağılım histogramı.....	46
Şekil 40. Bağcılar veri setindeki hastaların yaş dağılım grafiği.....	46
Şekil 41. Tüm veri setindeki anatomik bölgelerin dağılımını gösteren bar grafiği.....	48
Şekil 42. Eğitim veri setindeki anatomik bölgelerin dağılımını gösteren bar grafiği	48
Şekil 43. Validasyon veri setindeki anatomik bölgelerin dağılımını gösteren bar grafiği	49
Şekil 44. Test veri setinde anatomik bölgelerin dağılımını gösteren bar grafiği	49
Şekil 45. Tüm veri setine dahil edilen görüntülerin genişliklerinin (piksel) histogram grafiği	50
Şekil 46. Tüm veri setine dahil edilen görüntülerin yüksekliklerinin (piksel) histogram grafiği	50
Şekil 47. Tüm veri setine dahil edilen görüntülerin toplam piksel sayılarının karekökleri alınarak oluşturulmuş histogram grafiği	51
Şekil 48. Tüm veri setine dahil edilen görüntülerde bulunan kutucuk işaretlemelerin toplam piksel sayılarının karekökleri alınarak oluşturulmuş histogram grafiği.....	52

Şekil 49. Model eğitimi süresince eğitim ve validasyon aşamalarında kutucuk kayıp (box loss), nesnesellik kayıp (objectness loss) ile validasyon aşamasında kesinlik, duyarlılık, ortalama kesinlik (mAP) değerlerinin epochlar arasındaki değişimi.	53
Şekil 50. Validasyon (sol) ve test (sağ) veri setinde güven eşik değeri (confidence) ve F1 skoru ilişkisi	53
Şekil 52. Validasyon (sol) ve test (sağ) veri setinde güven eşik değeri (confidence) ve kesinlik (precision) ilişkisi	54
Şekil 51. Validasyon (sol) ve test (sağ) veri setinde güven eşik değeri (confidence) ve duyarlılık (recall) ilişkisi.....	54
Şekil 53. Validasyon (sol) ve test (sağ) veri setinde duyarlılık (recall) ve kesinlik (precision) ilişkisi	55
Şekil 54. Test veri setinde fraktür varlığı/yokluğu açısından radyologların model öncesi ve model ile birlikte değerlendirmelerine ait karıştırma (confusion) matrisleri	56
Şekil 55. Test veri setinde model tahminlerinin fraktür varlığı/yokluğu açısından karıştırma matrisleri (güven eşik değeri 0.05).....	57
Şekil 56. Bifid falanks olguda model tahmini.....	59
Şekil 57.Bifid falanks ve fraktür olan olguda model tahmini.	59
Şekil 58. Modelin fraktür olarak doğru tamin ettiği el radyografisi	60
Şekil 59. Modelin doğru negatif fraktür tahminine örnek.....	60
Şekil 60. Uyluk direkt radyografilerinde model tahminine örnekler	61
Şekil 61. Torus fraktürleri bulunan görüntüde modelin yanlış negatif tahmini	61
Şekil 62. 5. Metatars apofizinin yanlış pozitif model tahmini	62
Şekil 64. Pelvis direkt radyografilerine model tahmin örnekleri	63
Şekil 63. Modelin yanlış pozitif olarak değerlendirdiği görüntülere örnekler	63
Şekil 65. Modelin fraktür olarak doğru tahmin ettiği radyografilere örnekler.....	64
Şekil 66. Modelin fraktür olarak doğru tahmin ettiği el radyografilerine örnekler.....	64
Şekil 67. Modelin fraktür olarak doğru tahmin ettiği olgulara örnekler	65
Şekil 69. Modelin fraktür olarak doğru tahmin ettiği olgulara örnekler	65
Şekil 68. Modelin fraktür olarak doğru tahmin ettiği olgulara örnekler..	65

İÇİNDEKİLER

ÖNSÖZ.....	i
ÖZET.....	iii
ABSTRACT	vi
SİMGE VE KISALTMALAR.....	ix
TABLolar VE ŞEKİLLER	xi
İÇİNDEKİLER.....	xiv
1. GİRİŞ.....	1
2. GENEL BİLGİLER.....	3
2.1. X- IŞINLARI	3
2.1.1. X- ışını nasıl oluşur?.....	3
2.1.2. Radyografik Görüntünün Özellikleri.....	5
2.1.3. X – Işınlmasının Kullanım Alanları	6
2.1.4. Direkt Radyografi.....	6
2.2. KEMİK ANATOMİSİ	7
2.2.1. Kortikal (Kompakt) Kemik	8
2.2.2. Spongios (Tabeküler) Kemik	9
2.2.3. Uzun Kemiklerin Anatomisi.....	9
2.3. APENDİKÜLER İSKELET.....	11
2.3.1. Üst Ekstremitte Kemikleri	11
2.3.2. Alt Ekstremitte Kemikleri	14
2.3.3. Aksesuar Kemikler	15
2.3.4. Sesamoid Kemikler	18
2.4. KEMİK FRAKTÜRLERİ.....	19
2.4.1. Stres Kırığı	21
2.4.2. Çocuklarda Kemik Fraktürleri.....	21
2.4.2.1. Salter Harris Sınıflaması.....	24
2.4.3. Direkt Radyografilerde Fraktürle Karışabilen Normal Oluşumlar.....	26
2.5. YAPAY ZEKA VE OBJE TANIMA ALGORİTMALARI.....	30

2.5.1.	Yapay Zeka Nedir ?.....	30
2.5.2.	Derin Öğrenme	30
2.5.3.	Transfer Öğrenme.....	32
2.5.4.	Derin Öğrenme Tabanlı Nesne Tanıma Algoritmaları.....	33
3.	GEREÇ VE YÖNTEM	35
3.1.	VERİLERİN TOPLANMASI	37
3.2.	VERİ SETLERİNİN HAZIRLANMASI	37
3.3.	GÖRÜNTÜLERİN DEĞERLENDİRİLMESİ VE İŞARETLENMESİ (ANNOTASYON).....	38
3.4.	VERİLERİN ÖN İŞLEMLENMESİ VE VERİ ÇOĞALTIMI.....	39
3.4.1.	Ön İşleme	39
3.4.2.	Eğitim, Validasyon ve Test Veri Setlerinin Oluşturulması	40
3.4.3.	Veri Çoğaltımı	40
3.5.	MODEL YAPISI	40
3.6.	MODEL EĞİTİM SÜRECİ VE DOĞRULANMASI	43
3.7.	MODEL ÇIKTILARININ KİYASLANMASI.....	44
3.8.	İSTATİSTİKSEL ANALİZLER	44
4.	BULGULAR	45
4.1.	VAKA ÖRNEKLERİ	59
5.	TARTIŞMA	66
6.	SONUÇ.....	75
	KAYNAKÇA	76

1. GİRİŞ

Kemiğin anatomik bütünlüğünün veya devamlılığının bozulmasına kırık (fraktür) denir. Fraktürler en sık rastlanan kemik patolojileri arasında yer alırlar (1). İskelet sistemi apendiküler ve aksiyel iskelet olarak sınıflandırılır. Aksiyel iskeleti omurga (columna vertebralis), kranium ve toraks kemikleri oluştururken apendiküler iskeleti alt ve üst ekstremitelerde kemikleri oluşturur (2,3). Direkt radyografiler X ışını içeren görüntüleme yöntemi olup kas iskelet sisteminin patolojilerinde keşfedildiği tarihten itibaren en temel değerlendirme yöntemi olarak önemini korumaktadır. X ışınları ile elde edilen görüntülerde kemikler yüksek absorpsiyon değerleri gösterdiği için çevresindeki yumuşak dokulardan doğal bir kontrast oluşturmaları sayesinde direkt ayrıt edilebilirler. Kolay ulaşılır, hızlı ve ucuz olma özellikleri direkt radyografilerin en önemli avantajlarından (4).

Derin öğrenme çok katmanlı yapay sinir ağından oluşan, görüntü sınıflama, nesne tanıma, dil çevirisi, konuşma tanıma, doğal dil işleme ve oyun oynama gibi birçok alanda başarı kazanan ve ilgi çeken bir makine öğrenmesi alt tipidir (5). Derin öğrenme algoritmalarının son zamanlardaki büyük gelişimi ile derin öğrenme yöntemleri; mamografide meme kanseri tespiti (6), BT’de karaciğer metastazlarının segmentasyonu (7), HRCT’de interstisyel akciğer hastalıklarının sınıflaması (8), MRG’de beyin tümörü segmentasyonu (9) gibi birçok tıbbi görüntülemelerde kullanılmıştır.

Kemik fraktürleri acil servislerde çok yaygın görülen ortopedik travmatik acil sebeplerinden biridir. Travma sonrası kırık tespitinde direkt radyografi ilk başvurulması gereken tanı yöntemidir. Fakat bazı fraktürlerin direkt radyografi ile tanı konulması hem radyologlar hem de diğer branş doktorları için oldukça zorlayıcıdır. Acil servislere başvuran hastaların direkt radyografide fraktürlerin yanlış yorumlanması hasta tedavisinde gecikme ve geç tedavi edilen hastalarda kötü sonuçlara neden olur (10) ve aynı zamanda tıbbi davaların en sık nedenlerinden biridir (11). Radyografilerde gözden kaçan kırıklar, radyolog olmayan doktorlar veya tecrübesiz radyologlar tarafından yapılan ilk yorumlar ile tecrübeli acil radyologları tarafından yapılan son yorumlama arasındaki farklılıkların en yaygın nedenlerinden biridir ve önlenemez hasara/hasta tedavisinde gecikmeye yol açar. Acil servislerde yanlış tanı konulan ve bunun sonucunda hastanın zarar gördüğü durumların %41-%80’nini direkt radyografide görülen kırıkları yanlış yorumla oluşturur (12-14). İskelet yaralanmalarının, özellikle de apendiküler iskelet yaralanmalarının geç teşhis edilmesi veya gözden kaçması, radyografideki malpraktis davalarının en büyük nedenidir (15-17). Son

yıllarda derin öğrenme yöntemleri kullanılarak fraktür tespit eden çalışmalar, derin öğrenme teknolojisinin fraktür tespitinde kolaylık sağlayıp yanlış yorumlama oranını belirgin azaltmada yardımcı yöntem olarak kullanılabildiğini göstermiştir (18) ve bazı yayınlar derin öğrenme algoritmalarıyla fraktür tespitinin özgüllük ve duyarlılığının %90 ve üzeri olarak raporlanmıştır (19). Genel olarak bu çalışmalar direkt radyografileri el bileği (20), omuz (21), ayak bileği (22), kalça (23) gibi tek bir bölge ile sınırlandırarak fraktür tespitinde yoğunlaşmıştır. Biz ise çalışmamızda insan vücudundaki apendiküler iskeleti içeren direkt radyografilerde derin öğrenme tabanlı nesne tanıma algoritması ile otomatik fraktür tespiti yapmayı ve bu radyografileri yorumlayacak olan hekimlerin duyarlılığını artırmayı, hekimlere karar destek mekanizması sağlamayı, tanı koyma süresini kısaltmayı, fraktürlerin gözden kaçmasını önleyerek yanlış/eksik tanı sonrası oluşabilecek komplikasyonları ve bunun sonucunda da hekimlerin karşılaşabileceği malpraktis davalarını önlemeyi hedefledik.

2. GENEL BİLGİLER

2.1. X- Işınları


2.1.1. X- ışını nasıl oluşur?

X- ışını; iyonize radyasyon içeren tanısal radyolojik incelemelerin büyük bir bölümünü oluşturur. İlk kez 8 Kasım 1895'te Alman fizik profesörü Dr. Wilhelm Conrad Röntgen tarafından ortamda bulunan floresan ışığının parlaması sırasında keşfedilmiştir. Profesör bu buluşunu daha sonra karısının el radyografisini çekerek kullanmış ve elde ettiği fotoğrafla karısının parmak kemiklerini ve evlilik yüzüğünü gösterebilmiştir (Şekil 1). 1901 yılında Profesör Röntgen X-ışınını buluşu ile dünyada ilk kez verilen Nobel fizik ödülüne layık görülmüştür.




Şekil 1. Röntgen'in eşi Anna Bertha Ludwig'in el radyografisi

X-ışınları; dalga boyları 10 ile 0,01 nanometre arasında değişen, elektronların yavaşlatılması veya atomların iç yörüngelerindeki elektron yer değişimleri ile meydana gelen elektromanyetik dalgalar veya foton demetidir. Elektromanyetik dalga spektrumunda mor ötesi ışınlar ve gama ışınları arasında yer alırlar (24) (Şekil 2).



Şekil 2. Elektromanyetik spektrum, X-ışınları görünür ışıktan daha az dalga boyuna ve daha fazla enerjiye sahiptir. Dalga boyu küçüldükçe ışının enerjisi artar


X-ışınları oluşumu için havası alınmış cam bir tüp içinde (Crookes tüpü) serbest elektron ortaya çıkmalı, bu elektron daha sonra hızlandırılmalıdır. Sonrasında ise hızlandırılmış elektronlar yüksek atom numaralı herhangi bir madde ile çarpıştırılmalıdır. Elektronlar röntgen tüpü (Crookes tüpü) içinde katoda uygulanan akım sonrasında ortaya çıkar. Katoda verilen akım ortaya çıkan elektronların sayısını belirler ve bu miliamper (mA) ayarı ile belirlenir. Katotta ortaya çıkan elektronların anoda doğru hızlandırılması uygulanan gerilim ile alakalıdır ve kilovolt (kV) ayarı ile sağlanır. Katottan anoda doğru hızlandırılan atomlar anottaki yüksek atom numaralı maddeye (tungsten) çarptığında X ışını ortaya çıkar (24,25), (Şekil 3). Katottan fırlatılan elektronlar anoda çarptıkları zaman dururlar ve kinetik enerjileri başka enerji şekillerine dönüşür. Enerjinin korunması prensibine göre, röntgen cihazlarında gerçekleşen değişim ile bu enerjinin %99,8'i ısıya dönüşürken sadece %0,2'si hedef anot materyalinin atomları ile etkileşime girerek X-ışınını oluşturmaktadır (26,27). X-ışını oluşurken çok yüksek bir ısı açığa çıktığı için anod materyali Tungsten gibi erime noktası çok yüksek bir maddeden yapılır.



Şekil 3. X-ışının oluşumu

2.1.2. Radyografik Görüntünün Özellikleri

X-ışını hastanın vücuduna ulaştığında bir kısmı vücutta absorbe olur, bir kısmı vücudu geçer ve doğrudan görüntü alıcıya ulaşır (transmisyon), bir kısmı ise saçılır. Radyografik görüntü oluşumunda absorpsiyon ile transmisyon rol oynar, saçılan radyasyon anlamlı görüntü oluşturmaz (28). Radyolojik görüntünün ana belirleyicisi absorpsiyondur ve insan vücudundaki dokuların absorpsiyon özellikleri farklıdır (Şekil 4). X-ışının enerjisi arttıkça absorpsiyon o kadar azalır. Dokuların atom ağırlığı, yoğunluğu ve kalınlığı arttıkça da absorpsiyon artar. İnsan vücudu farklı atom ağırlığında, kalınlığında ve yoğunluğunda dokulardan oluştuğu için farklı oranlarda X-ışını absorbe eder (29).



Şekil 4. Radyografik görüntüde doku yoğunlukları farklı olduğundan kemikler beyaza yakın, yumuşak dokular ise gri tonları şeklinde ortaya çıkar (Görsel Trd Sem 2017; 5: 1-22 sayısındaki Radyografinin Temel Prensipleri ve Radyografik Yorumda Temel İlkeler yazısından alıntıdır (25)).

Bir radyolojik görüntü aslında dokulardaki absorpsiyonun oluşturduğu gölge grafisidir fakat radyogramdaki gölgeler normal gölgelerden farklı olarak beyaz veya beyaza yakındır. Işının fazla geçtiği dokular siyah veya siyaha yakın olarak izlenir. Radyolojik görüntüde; siyah - siyaha yakın gri – gri – beyaza yakın gri – beyaz olarak 5 ana yoğunluk bulunur. Bu yoğunlukların temsil ettiği dokular farklıdır. Siyah hava, siyaha yakın gri yağ, gri su ve yumuşak doku, beyaza yakın gri kemik ve kalsifikasyon, beyaz metal ve kontrast maddelerin gölgelerine karşılık gelir. Yan yana gelen vücut dokuları aynı doku yoğunluğuna sahip ise radyografide ayırt edilemezler. Radyografi başlıca akciğer veya ekstremiteler kemikleri gibi doğal kontrast farkının belirgin olduğu dokularda diğer dokulara kıyasla daha başarılıdır (25).

2.1.3. X – Işınlının Kullanım Alanları

X-ışınları Röntgen tarafından keşfedilmesinden sonra günümüze dek günlük hayat içinde çok önemli ve yaygın kullanım alanları bulmuştur. X-ışınlarının farklı alanlarda çeşitli kullanımları vardır. Tıp alanında ve tıp dışı alanlarda birçok yerde kullanılır. Tıp alanında kullanım alanları şunlardır direkt radyografi, mamografi, floroskopi, bilgisayarlı tomografi, radyoterapide kullanılır

Tıbbi uygulamalara ek olarak, uzay araştırmalarında X-ışınları Mars kayalarındaki çinko ve nikel gibi elementleri tespit etmek için ve kozmosu keşfetmek için de kullanılır (30)

2.1.4. Direkt Radyografi

Direkt radyografiler; kemik kırıkları, tümörler, pnömoni, yaralanmalar, kalsifikasyonlar, yabancı cisimler veya dental problemleri tespit etmek için kullanılır. Özellikle kas iskelet sisteminin değerlendirmesinde keşfedildiği tarihten itibaren en temel görüntüleme yöntemi olarak yerini korumaktadır. X ışınları ile elde edilen görüntülerde kemikler yüksek absorpsiyon değerleri gösterdiği için çevresindeki yumuşak dokulardan doğal bir kontrast oluşturmaları sayesinde direkt ayırt edilebilirler. Kolay ulaşılır, hızlı ve ucuz olma özellikleri en önemli avantajlarındandır (4).

Direkt grafiler değerlendirilirken ilk olarak hastanın yaşı, cinsiyeti, taraf bulgusu, klinik öykü ve labratuar bulguları değerlendirilmelidir. Radyografi değerlendirilirken sistematik ilerlemek ve yalnızca kuşku yere bakmamak çok önemlidir. Kas ve yumuşak dokular, kemik korteksi-periostu-medullası, eklem aralığı ve hasta çocuk ise epifiz hatları sistemli şekilde değerlendirilmez (31). Bir patoloji varsa bunu tanımlayabilmek için önce normal radyografik anatomi ve varyasyonları bilmek gerekir.

2.2. Kemik Anatomisi

Kemikler; kemik, kıkırdak, yağ, bağ dokusu, hematopoietik doku, sinirler ve damarlar dahil olmak üzere çok sayıda dokudan oluşan organlardır. Yenidoğanlarda yaklaşık 270 adet kemik vardır ve bunlar yetişkin insanda birleşerek 206 ile 213 adet kemiğe dönüştür (sesamoid kemikler ve kulak kemikçikleri hariç). Kemik sayısındaki değişkenliğin nedeni, bazı insanların değişen sayıda aksesuar kemik, kosta, vertebra ve falankslara sahip olabilmesidir. Kemikler şekillerine göre uzun kemikler, kısa kemikler, yassı kemikler, irregüler kemikler ve sesamoid kemikler olarak sınıflandırılırlar (32) (Tablo 1).

Tablo 1. Kemiklerin şekillerine göre sınıflandırılması			
Kemik Sınıflaması	Şekil	Fonksiyonlar	Örnekler
Uzun Kemikler	Silindir benzeri şekil, uzunluğu kalınlığından fazla	Kaldıraç görevi, kaslar kasıldığında hareket ederler	Femur, tibia, fibula, metatarsal kemikler, humerus, ulna, radius, metacarpal kemikler, falankslar
Kısa Kemikler	Küpe benzeri şekil, yaklaşık olarak uzunluğu genişliği eşit	Stabilite ve desteğin yanı sıra sınırlı hareket sağlar	Karpal ve tarsal kemikler
Yassı Kemikler	İnce ve kavisli	Kaslar için bağlantı noktaları sağlar, iç organları korur	Sternum, kotlar, skapula, kranial kemikler
İrregüler Kemikler	Kompleks şekil	İç organları korur	Vertebra, sakrum, koksiks, hyoid kemik, yüz kemikleri
Sesamoid Kemik	Küçük ve yuvarlak	Tendonları başınç kuvvetlerinden korur	Patella


Kemikler esnek bir matris (yaklaşık %30) ve bağlı minerallerden (yaklaşık %70) oluşur. Kemik matrisinin %90 ila 95'i ossein olarak da bilinen elastik kollajen liflerinden oluşur.

Kollajen esnek olduđu için kırılma direncini artırır. Matris, kalsiyum hidroksilapatitin bir formu olan kemik minerali olarak bilinen kimyasal bir düzenlemede inorganik mineral tuzu olan kalsiyum fosfatın bağlanmasıyla sertleştirilir. Kemiklere sertlik veren mineralizasyondur.

Yapılarına göre kemikler kortikal ve spongioz kemikler olarak ikiye ayrılırlar.

2.2.1. Kortikal (Kompakt) Kemik

Kemiklerin sert dış tabakası, süngerimsi kemikten çok daha yoğun olduđu için kompakt kemik olarak da adlandırılan kortikal kemikten oluşur. Kemiklerin sert dış kısmını (korteksi) oluşturur. Kortikal kemik kemiğe pürüzsüz, beyaz ve sağlam bir görünüm verir ve yetişkin bir insan iskeletinin toplam kemik kütesinin %80'ini oluşturur. Her biri osteon veya Havers sistemi olarak adlandırılan çok sayıda mikroskobik sütundan oluşur. Her sütun, havers kanalı adı verilen merkezi bir kanalın etrafındaki çok sayıda osteoblast ve osteosit katmanından oluşur. Volkmann kanalları dik açılarla osteonları birbirine bağlar (Şekil 5). Kortikal kemiğin dış yüzeyi periosteum, iç yüzeyi ise endosteum ile örtülüdür. Endosteum, kortikal kemik ile süngerimsi kemik arasındaki sınırdır. Kortikal kemiğin birincil anatomik ve işlevsel birimi osteondur (33).



Şekil 5. Kortikal kemikteki Havers ve volkman kanalları (Görsel Anatomy and Physiology 2e (2022) kitabından alıntıdır (34)).


2.2.2. Spongioz (Tabeküler) Kemik

Süngerimsi (spongioz) kemik, kortikal kemiğe kıyasla göre daha fazla yüzey alanı-hacim oranına sahiptir ve daha az yoğundur, daha esnektir. Süngerimsi kemik tipik olarak uzun kemiklerin uçlarında, yassı kemiklerin iç kısımlarında bulunur.

Süngerimsi kemik oldukça vaskülerdir ve genellikle kan hücrelerinin üretimi olan hematopoezin meydana geldiği kırmızı kemik iliği içerir. Süngerimsi kemiğin birincil anatomik ve işlevsel birimi trabeküldür. Endosteumla kaplı ince osteoblast oluşumları, trabekül olarak bilinen düzensiz bir boşluk ağı oluşturur. Bu boşlukların içinde trombosit, kırmızı kan hücreleri ve beyaz kan hücrelerini oluşturan kemik iliği ve hematopoietik kök hücreler bulunur. Trabeküler kemik iliği, genel organı daha hafif yapan ve kan damarları ile kemik iliği için yer sağlayan çubuk ve plaka benzeri elementlerden oluşan bir ağdan oluşur. Trabeküler kemik, toplam kemik kütlesinin geri kalan %20'sini oluşturur, ancak kompakt (kortikal) kemiğin yüzey alanının neredeyse on katına sahiptir.


2.2.3. Uzun Kemiklerin Anatomisi

Uzun kemiğin diafiz ve epifiz olmak üzere 2 ana yapısı bulunur. Diafiz kemiğin tübüler shaftı olup içindeki boşlukta medüller kavite yer alır ve burada sarı kemik iliği bulunur. Uzun kemiklerin her iki ucunda süngerimsi kemik ile dolu epifiz yer alır (Şekil 6). Kırmızı kemik iliği buradaki boşlukları doldurur. Epifiz, diafiz ile epifiz (büyüme) tabakasını içeren hyalin kıkırdak ile kaplı dar bir alan olan metafiz düzeyinde buluşur. Bu tabaka kemik büyümesi durduğunda epifiz hattı haline gelir.



Şekil 6. Uzun kemiklerin anatomisi (Görsel Anatomy and Physiology 2e (2022) kitabından alıntıdır (34)).

Medüller kavite, kemik büyümesinin, onarımının ve yeniden şekillenmesinin meydana geldiği endosteum adı verilen hassas bir membranöz tabakaya sahiptir. Kemikğin dış yüzeyi, periosteum adı verilen fibröz bir membran ile kaplıdır. Periosteum, kompakt (kortikal) kemikği besleyen kan damarlarını, sinirleri ve lenfatik damarları içerir. Tendonlar ve bağlar da periosteuma tutunup kemiklere bağlanır. Periosteum, epifizlerin eklem oluşturmak üzere diğer kemiklerle birleştiği yerler dışında tüm dış yüzeyi kaplar (Şekil 7). Bu bölgede epifizler, sürtünmeyi azaltan ince bir kıkırdak tabakası olan eklem kıkırdağı ile kaplıdır. El bileğindeki 8 karpal kemik ve ayak bileğindeki 7 tarsal kemik ve patella hariç ekstremitelerdeki tüm kemikler uzun kemiktir.



Şekil 7. Periost ve endosteum (Görsel Anatomy and Physiology 2e (2022) kitabından alıntıdır (34))

2.3. Apendiküler İskelet


İskelet sistemi apendiküler ve aksiyel iskelet olarak sınıflandırılır. Aksiyel iskeleti omurga (columna vertebralis), kranium ve toraks kemikleri oluştururken apendiküler iskeleti alt ve üst ekstremitelerde kemikleri oluşturur (2,3). Apendiküler iskelette skapula-klavikula (4 adet), humerus-radius-ulna (6 adet), karpal-metakarpal-el falanksları (54 adet), pelvis (2 adet), femur-patella-tibia-fibula (8 adet), tarsal-metatarslar-ayak falanksları (52 adet) olmak üzere toplam 126 kemik bulunur (32) .

2.3.1. Üst Ekstremité Kemikleri


Üst ekstremité kemikleri proksimalden distale omuz kuşağı, kol, ön kol ve el iskeletinden oluşur.

Omuz kuşağı kemiklerini klavikula ve skapula oluşturur. Omuz kuşağını önden klavikula, arkadan ise skapula kuşatır. Kol iskeletini humerus, ön kol iskeletini radius ve ulna oluşturur (Şekil 8). El iskeletini; el bilek kemikleri (ossa carpi), el tarak kemikleri (ossa

metacarpi), el parmak kemikleri (phalanges, ossa digitorum manus) oluşturur (Şekil 9).




Şekil 8. Üst ekstremité anatomisi (Görsel Sobotta Atlas of Human Anatomy kitabından alıntıdır (35)).



Şekil 9. El iskeleti anatomisi (Görsel Sobotta Atlas of Human Anatomy kitabından alıntıdır (36)).

2.3.2. Alt Ekstremité Kemikleri

Alt ekstremité pelvis kemikleri ve alt ekstremité serbest kemikleri olarak ikiye ayrılır. Alt ekstremité serbest kemikleri uyluk, bacak (kruris), ve ayak olmak üzere üç bölüme ayrılır. Uyluk kemiğini femur(os femoris), bacak(ossa cruris) kemiklerini tibia ve fibula oluşturur (Şekil 10). Ayak iskeleti kemiklerini(ossa pedis); ayak bilek kemikleri(ossa tarsi), ayak tarak kemikleri(ossa metatarsi), ayak parmak kemikleri(phalanges, ossa digitorum pedis) oluşturur (Şekil 11).



Şekil 10. Alt ekstremité anatomisi (Görsel Sobatto Atlasından elde edilmiştir).




Şekil 11. Ayak iskeleti anatomisi (Görsel Sobatto Atlasından elde edilmiştir).

2.3.3. Aksesuar Kemikler

Her insanda bulunmayan normalden fazla sayıdaki kemiklerdir. Vücutta daha çok ayak kemikleri rasında bulunan aksesuar kemikler direkt radyografi görüntülerinde kırık kemik parçası olarak değerlendirilebilir (37).


El bileğinde 20'den fazla aksesuar kemik tarif edilmiş olup (38) daha yaygın olanları os styleoideum, os triangulare, os epilunate, os hamuli proprium, lunula, trapezium secundarium, os radiostyloideum, persistant ulnar stiloid, os epilunatum olarak sayılabilir (Şekiller)



Şekil 12. El bileğinde olabilecek aksesuar kemikler (Görsel Radiopedia.com, Ossicles of the wrist and hand (illustration) başlıklı içerikten alıntıdır.)



Şekil 13. El bileğindeki aksesuar kemiklerden os triangulare. Os triangulare ulnar styloid, lunatum ve triquetrum arasında yer alır ve non-union ulnar styloid proçes fraktürleri ile karışır (Görsel radiopaedia.com web sitesinden alıntıdır, URL: <https://radiopaedia.org/cases/os-triangulare-1>).



Şekil 15. Ayakta görülen bazı aksesuar kemikler (Görsel radiopaedia.com web sitesinden alıntıdır, URL : <https://radiopaedia.org/articles/accessory-ossicles-of-the-foot>)

2.3.4. Sesamoid Kemikler

Sesamoid kemikler, genellikle eklem yüzeylerinin yakınında bir kas veya tendon içinde gömülü olarak bulunan, söz konusu kas veya tendon üzerindeki baskıyı hafifletmek için bir kasnak görevi gören küçük bir kemiklerdir. Eklemler yoluyla bağlanan standart kemiklerin aksine, sesamoid kemikler kaslara tendonlar aracılığıyla bağlanır (41). Bu kemikler genellikle kaslara ve tendonlara eklenen gerginliğe yanıt olarak oluşturulur. Sesamoid kemikler kaslar ve tendonlardaki gerilimi azaltır; kas ve tendon üzerindeki kuvveti yeniden dağıtarak artan kasları ve tendonları önemli gerilme ve yaralanmalardan korur. Çoğu sesamoid kemiği küçük olsa da, genel sürtünmeyi azaltır ve vücudumuzun benzersiz biyomekaniğine ve farklı hareket aralığına izin verir. Bazıları normal anatomik olarak bulunurken (patella), bazıları da anatomik varyant olarak bulunur. En sık olarak elde rastlanır, 1. Metakarpofalangeal eklem sesamoid kemiklerinin (Şekil 16) insidansı % 100 olarak bulunmuştur (42).




Şekil 16. 1. Metaparpofalengeal eklem sesamoidi, insidansı %100 olarak bulunmuştur (Görsel Bağcılar Eğitim ve araştırma hastanesi vakalarından elde edilmiştir).

2.4. Kemik Fraktürleri

Kemiğin anatomik bütünlüğünün veya devamlılığının bozulmasına kırık (fraktür) denir. Kırıklar en sık rastlanan kemik patolojileri arasında yer alırlar (1). Kırıklar aşağıdaki gibi sınıflandırılır.


- Komplet veya inkomplet fraktür,
- Üstteki yumuşak doku sağlamısa kapalı, kırık hattı yüzeydeki cilde dek uzanıyorsa açık fraktür
- Kemik birden çok fragmana ayrılmışsa parçalı fraktür
- Kırık uçları biriri ile aynı hizada değilse deplase aynı hizada ise nondeplase olarak sınıflandırılır.

Mekanizmasına göre travmatik veya patolojik olarak sınıflandırılır. Eğer kırık yerinde altta yatan ve kemiği zayıflatan kist, tümör, osteoporoz gibi bir sebep varsa patolojik fraktürden bahsedilir. Fraktür şekline göre ise; lineer, transvers, oblik, spiral, kompresyon, greenstick (yaş ağaç kırığı), torus, bükülme, impakte veya avülsion fraktürü olarak sınıflandırılabilir (Şekil 17).



Şekil 17. Bazı fraktür çeşitleri görselleri (Görsel Anatomy and Physiology 2e (2022) kitabından alıntıdır (34)).

Kemik kırıldığında kırık alanında kan ve pıhtı ile karışık iyileşmeye yardımcı granülasyon dokusu oluşur. İltihabi hücreler bir dizi büyüme faktörleri salgılayarak öncül kemik hücrelerini uyarırlar ve yeni matris sentezine başlanır. Granülasyon dokusu önce kompakt bağ dokusu daha sonra da kırıkta dokusu karakterini alır ve kallus adı verilen bir alan oluşur. Kallusta önce spongioz daha sonra kompakt kemik dokusu oluşur (1) (Şekil 18).




Şekil 18. Sırasıyla kemik fraktürünün iyileşme aşamaları: (a) Hematom aşaması. (b) İnternal ve eksternal kallus formasyonu. (c) Kırıkdağın spongioz kemiğe dönüşümü (d) İyileşmesi tamamlanmış fraktür (Görsel Anatomy and Physiology 2e (2022) kitabından alıntıdır (34)).

2.4.1. Stres Kırığı

Stres kırıkları, kemik kuvveti ile uzun süreli mekanik stres arasındaki uyumsuzluk nedeniyle oluşan kırıklardır. Yetmezlik ve yorgunluk kırıkları olmak üzere iki tipi vardır. Yetmezlik kırıkları; osteoporoz, osteomalazi, Paget hastalığı, fibröz displazi, osteogenezis imperfekta, radyasyon, hiperparatiroidizm, anoreksiya vb. hastalarda anormal kemik üzerindeki normal strese bağlı olarak ortaya çıkar. Yorgunluk kırıkları, normal kemiğin anormal tekrarlayan strese tepkisi nedeniyle oluşur. Bunlara genellikle ya aniden yorucu bir spor aktivitesine giren kondisyonsuz bireylerde ya da antrenman rejimini akut bir şekilde yoğunlaştırmış antrenmanlı kondisyonlu sporcularda rastlanır (43).

Erken evre stress kırıklarında direkt radyografilerin hassasiyeti zayıftır (%15-35), geç dönemde olası kallus oluşumu nedeniyle bu hassasiyet artar (%30-70). MRG, stres kırığının teşhisi için en hassas yöntemdir ve %100'e yakın olduğu bildirilen bir hassasiyete sahiptir (44).



Şekil 19. A) Sol femur boynunda ve B) Kalkaneusta lineer sklerotik-radyoopak bir stres kırığı hattı (Görsel radiopaedia.com web sitesinden alıntıdır URL: <https://radiopaedia.org/cases/45605/studies/49737> ve <https://radiopaedia.org/cases/11970/studies/12333>).

2.4.2. Çocuklarda Kemik Fraktürleri

Kırıklar, erkek çocuklarda daha yaygın olmak üzere, çocuklardaki yaralanmaların %25'ini oluşturur (45). Çocuklarda görülen kırık tipleri ve mekanizması çocuk iskeleti ve fizyolojisinin farklı olması nedeniyle erişkinlerde görülenlerden önemli derecede farklıdır. Bir

çocuğun kemikleri bir yetişkininkinden daha esnektir. Büyüme plakası (growth plate) etrafındakiler de dahil olmak üzere çocuk iskeletinde daha fazla miktarda kırık vardır, havres kanalı ve vasküler kanal sayısı erişkinle kıyaslandığında daha fazladır, inorganik mineraller ise çocuk kemiklerinde daha az bulunur (46). Çocuk periostu erişkine kıyasla daha kalındır ve bütünlüğünün bozulması daha zordur.

Bir kemiğe kuvvet uygulandığında, o kemik içinde sıkıştırma, çekme gibi gerilimler oluşturur. Bu gerilime neden olan stres faktörleri arttıkça kemik deformasyonu başlar, strese neden olan kuvvet kaldırıldığında ise kemik normale dönebilir. Kuvvet uygulanan ve stres faktörü ortadan kalkan kemik başlangıçta radyografik olarak normal olabilir, ancak takip eden radyografiler mikro kırıklara yanıt olarak iyileşen bir periosteal reaksiyonu gösterebilir. Stres kuvvetinin daha fazla artmasıyla, kemik nihai stres noktasına ulaşır ve ardından kırılır.


Yetişkinlerde bükülme noktası ve nihai stres noktaları birbirine çok yakındır ve plastik deformite nadirdir. Küçük çocuklarda, kemik daha fazla elastik dereceye sahip olduğundan, bükülme noktası ile nihai stres noktası arası birbirine uzaktır ve eğilme gibi plastik deformiteye sahiptir. Kortikal kemik, sıkıştırma gerilimlerini çekme veya kesme kuvvetlerinden daha iyi tolere eder. Sonuç olarak, çocukluk çağında kırıklar tam veya kısmi (inkomplet) olabilir. İki veya daha fazla kemik parçası arasında tam bir devamsızlık olduğunda komplet bir kırık meydana gelir. İnkomplet kırıklarda ise kemiğin artmış esnekliği nedeniyle korteksin bir kısmı sağlam kalır.

İnkomplet fraktürler arasında greenstick(yeşil ağaç), buckle(torus) ve plastik bowing(bükülme) fraktürleri bulunur (Şekil 20, Şekil 21, Şekil 22).



Şekil 20. Tibia ve fibulada distal diafiz yerleşimli kemiğin tek bir taraf korteks ve periostunun kesintiye uğradığı inkomplet greenstick fraktürü.(Görsel Grainger & Allison's Diagnostic

Radiology kitabında Karen et. Al. Yazmış olduğu Pediatrik Fraktürler bölümünden alıntıdır (45)).




Şekil 21. El bilek AP (A) ve lateral (B) direkt radyografi görüntülerinde distal radiusta inkomplet fraktür olan buckle (torus) fraktürü görülmekte. AP radyografide kolaylıkla gözden kaçabilecek torus fraktürü lateral radyografide kortikal düzensizlik olarak daha iyi gözleniyor.(Görsel Grainger & Allison's Diagnostic Radiology kitabında Karen et. Al. Yazmış olduğu Pediatrik Fraktürler bölümünden alıntıdır (45)).



Şekil 22. Ön kol AP(A) ve lateral(B) radyografi, AP radyografi tamamen normal iken lateral radyografide ulnada volar yüze doğru belirgin bükülme izlenmekte. Bükülme (bowing) fraktürlerinde gözle görülür bir fraktür hattı seçilemez (47). (Görsel radiopaedia.com web sitesinden alıntıdır URL: <https://radiopaedia.org/cases/44172/studies/47758>).

Apofiz ise eklemlerle ilişkisi olmayan tendonların yapıştığı sekonder ossifikasyon merkezleridir ve esas olarak osteokartilajinöz bir çıkıntıdır. Kemik üzerindeki tendon ve kasların eki gibi düşünülebilir. Trokanter major, tuberositas tibia (48) ya da olekranon örnek

olarak verilebilir (Şekil 23). Apofizler, apozisyonel büyüme ile genişleyerek büyür. Kemik boyunun artışına katkı sağlamaz. Direkt radyograflerde kırık ile karışabilir.



Şekil 23. Diz lateral direkt radyografi görüntüsünde patellar tendonun tibia yapışma yeri olan tuberositas tibia izleniyor (Görüntü Bağcılar Eğitim ve Araştırma Hastanesi vakalarından elde edilmiştir).


2.4.2.1. *Salter Harris Sınıflaması*

Erişkinlerde, uzun kemikler anatomik olarak epifiz, metafiz ve diyafiz olarak ayrılır. Çocuk kemiklerinde ise büyüme plağı (fizis) ile sekonder ossifikasyon merkezlerinin bulunması erişkinlerden farklıdır ve travmaya yanıtta önemli ölçüde biyomekanik farklılıklara neden olur.

Büyüme plağı (fizis), epifiz ile metafiz arasında kalan ve uzunlmasına büyümeden sorumlu kıkırdaktan oluşan radyolusen hattır, bölünüp çoğalarak yeni kemik oluşturur (Şekil 24). Büyüme devam ederken, çocuk büyüdükçe epifiz düzeyinde sekonder ossifikasyon merkezi gelişir ve fizis hattı daralır. Büyüme plağında epifizden metafize doğru; rezerv bölge, proliferatif bölge, hipertofik bölge, metafizer bölge olmak üzere 4 bölüm bulunur (49). Fizis hattı çevre kemik ve ligamentlerden daha zayıf bir bölgedir ve yaralanmalarda etkilenir. Çocuklarda tübüler kemik kırıklarının %15'inde büyüme plağı (fizis) etkilenir (45). Büyüme plağı kırıkları sınıflamasında en sık olarak Salter-Harris sınıflandırılması kullanılır (50). Bu sınıflama ilk kez Salter ve Harris tarafından 1963'te oluşturulmuştur ve 5 farklı tipe ayrılır (Şekil 25 ve Tablo 2).



Şekil 24. Çocuklarda büyüme plağı (fizis) radyolusen olarak görülür (Görsel Bağcılar Eğitim Araştırma hastanesi vakalarından elde edilmiştir).



Şekil 25. Salter-Harris sınıflaması görseli (45)

Tablo 2. Salter-Harris sınıflaması tipleri		
Fraktür Tipi	Tahmini İnsidans	Tanım
I-Slipped(kaymış)	%5	Kırık hattı büyüme plağının hipertofik bölgesindedir, fizisin kemikten ayrıldığı kırık tipleridir. Komşu kemikte kırık izlenmez. Bir kırık hattı seçilemez.

		Prognozu iyidir. Direkt radyografide görünüm normal olabilir.
II-Above(üstünde)	%75	Kırık hattı fizisi geçerek metafize uzanır ve metafizden küçük bir parça koparır. Prognozu iyidir.
III-Below(altında)	%10	Kırık hattı fizisten epifize uzanır. Rezerv bölge ve proliferatif bölge kesintiye uğrar. Prognoz kötüdür.
IV-Trough(içinden)	%10	Kırık hattı metafiz, fizis ve epifizin hepsinden geçer. Rezerv bölge ve proliferatif bölge kesintiye uğrar. Prognoz kötüdür.
V-Ruined(bozulmuş)	<%1	Büyüme plağının epifiz ve metafiz arasında sıkıştığı, kompresyona uğradığı kırıklardır. En kötü prognoz bu sınıfa aittir, büyüme bozukluğuna neden olur. Bir kırık hattı seçilemez. Direkt radyografi genel olarak normaldir.

2.4.3. Direkt Radyografilerde Fraktürle Karışabilen Normal Oluşumlar

Direkt radyografilerde birçok anatomik varyasyon, apofizler, aksesuar kemikler, sesamoid kemikler, füzyzone olmamış ossifikasyon merkezleri, avasküler nekroz, uzun



Şekil 26. Çocuk ayak radyografilerinde 5. Metatars proksimalinin kemiğin shaftına paralel uzanan normal apofizi (A) ve aşıl tendonun kalkaneusa yapışma yeri olan kalkaneal apofiz (B) görülüyor. Avulsion kırıkları ile karıştırmamak için normal olan bu görüntüleri bilmek önemli (Görseller Bağcılar Eğitim ve Araştırma Hastanesi vakalarından elde edilmiştir).

kemiklerin vasküler kanalları (nutritient foramen), cleft (yarık) epifiz, ligament kalsifikasyonları gibi oluşumlar kırık hattı veya kopmuş kemik parçası olarak yanlış yorumlanıp çoğu kez kafa karıştırıcı olabilir. Bunlardan bazıları şekillerle örneklendirilmiştir (Şekil 26, Şekil 27, Şekil 28, Şekil 29, Şekil 30, Şekil 31, Şekil 32). Özellikle çocuklarda füzyone olmamış sekonder ossifikasyon merkezleri kırık olarak yorumlanmaya çok açıktır, bunun için bazı durumlarda şikayet olan taraf dışında karşı taraf ile karşılaştırmalı radyografler tanıya yardımcı olur.



Şekil 27. Uzun kemiklerde kemiğin besleyici arterinin kortekten geçtiği, radyograflerde de izlenen radyolusen tünel Nutrient foramen (vasküler kanal) olarak adlandırılır. El(A) ve femur (B) radyograflerinde nutrient foramen örneği (Görseller Bağcılar Eğitim ve Araştırma Hastanesi vakalarından elde edilmiştir).



Şekil 28. Cleft (yarık) epifiz, epifizde görülen vertikal düzgün sınırlı radyolusen hatır ve normalin varyantıdır ve radyografilerde kırıkla karışabilir, bazen hastanın ağrı kliniği olduğunda oldukça kafa karıştırıcı olur. Normalin varyantı olan bu oluşumu bilmek yanlış tanı ve tedaviyi önler. A) Ayak radyografisinde 1. Pamak proksimal falanks epifisinde yarık şeklinde radyolusen hat B). Ayak bileği radyografisinde tibia epifizinde epifizi kat eden radyolusen yarık izleniyor (51) (Görsel radiopaedia.com web sitesinden alıntıdır URL: <https://radiopaedia.org/cases/24381/studies/24671>).



Şekil 29. Radial beak (gaga), Radius distalinde lateralde, kapanmış epifizin yanında küçük bir kemik çıkıntı (spur) olarak tanımlanır, kırıklarla karışır (Görsel Bağcılar Eğitim ve Araştırma Hastanesi vakalarından elde edilmiştir).



Şekil 30. Bipartite patella AP(A) ve lateral(B) diz radyogramlarında patellanın süperolateralinde ayrı bir küçük kemik izleniyor. Bipartite patella, patellanın aksesuar bir ossifikasyon merkezinin olduğu ve birbiri ile kaynaşamayan iki ayrı kemikten oluştuğu doğuştan bir durumdur ve en sık süperolateral kısımda görülür (52). Patellanın ikiden fazla ossifikasyon merkezlerinin olduğu durum ise multipartite patella olarak adlandırılır (Görsel radiopaedia.com web sitesinden alıntıdır URL: <https://radiopaedia.org/cases/12979/studies/13069>).



Şekil 31. Pellegrini-Stieda lezyonu, femur medial kondil medialinde medial femoral kollateral ligament (MCL) veya MCL femur insersiyosunda posttravmatik kemikleşme olarak tanımlanır (53) (Görsel radiopaedia.com web sitesinden alıntıdır URL: <https://radiopaedia.org/cases/11752/studies/32197>).



Şekil 32 Halluks sesamoid. A). Halluks sesamoid fraktürü, bipartit halluks sesamoidden ayrımı zor olup fraktür hattının şekilsiz ve düzensiz olması ile ayrılabilir. B). Bu görüntüde fraktür yok. Siyah ok başı: Os subratallere, ayakta aksesuar kemik, siyah ok: Normal hallux sesamoid (Görseller Bağcılar Eğitim ve Araştırma Hastanesi vakalarından elde edilmiştir).

2.5. Yapay Zeka ve Obje Tanıma Algoritmaları


2.5.1. Yapay Zeka Nedir ?

Yapay zeka kavramı 1950'lerin başında Alan Turing'in "makinler düşünebilir mi?" sorusuyla ortaya çıkan ve insan zekasını taklit eden uygulama veya makineleri kapsayan kavramdır (54). John McCarthy ise 1956 yılında yapay zeka terimini ilk defa bir konferansta kullanmış ve insan gibi düşünen akıllı makineler üretme mühendisliği olarak ifade etmiştir. En basit haliyle, bilgisayar bilimi ile sağlam veri kümelerini birleştirerek problem çözmeye olanak sağlayan bir alandır. Yapay zeka, makine öğrenimi ve derin öğrenmenin alt alanlarını kapsar. Bu alanlar, girdi verilerine dayalı olarak tahminler veya sınıflandırmalar yapan uzman sistemler yaratmaya çalışan yapay zeka algoritmalarından oluşur.

2.5.2. Derin Öğrenme

Derin öğrenme çok katmanlı yapay sinir ağından oluşan bir makine öğrenmesi alt tipidir. Derin öğrenme ve makine öğreniminin farklı olduğu yol, her bir algoritmanın nasıl

öğrenildiğidir. Derin öğrenme, sürecin özellik çıkarma parçasının çoğunu otomatikleştirerek, gerekli olan manuel insan müdahalesinin bir kısmını ortadan kaldırır ve daha büyük veri setlerinin kullanılmasını sağlar. Derin öğrenme; görüntü sınıflama, nesne tanıma, dil çevirisi, konuşma tanıma, doğal dil işleme ve oyun oynama gibi birçok alanda başarı kazanan ve ilgi çeken bir makine öğrenimi yöntemleri sınıfıdır (5). Girdilerden elle tasarlanmış özellik çıkarımı gerektiren geleneksel makine öğrenimi yöntemlerinden farklı olarak, derin öğrenme yöntemleri direkt olarak verilerden öğrenir (Şekil 33). Büyük veri setlerinin ve artan bilgi işlem gücünün ortaya çıkmasıyla, bu yöntemler olağanüstü performansa sahip modeller üretebilir (55). Yapay sinir ağının temel birimi olan yapay nöron veya düğüm, biyolojik nöronda bulunan temel mekanizmayı taklit eden basitleştirilmiş bir modeldir. Derin öğrenme algoritmaları; şekiller, lezyonlar veya organlar gibi karmaşık özelliklerin basit bileşenlerini (sinyal yoğunluğu, kenarlar ve dokular gibi) öğrenerek uçtan uca bir yaklaşım önerir (55).



Şekil 33. Makine öğrenmesi ve derin öğrenme şeması

Derin öğrenme ile model gelişiminde önce bir eğitim setine ihtiyaç duyulur. Eldeki verileri eğtmek için denetimli veya denetimsiz olmak üzere iki temel makine öğrenme modelinden yararlanılabilir. Denetimli öğrenmede her veri setindeki her örnek etiketlenir, denetimsiz öğrenmede ise veri setinde hiçbir etiketleme yapılmadan model veri setindeki doğal değişkenlikleri gruplayarak kendisi sınıflara ayırır. Denetimsiz öğrenme ile uygulamada iyi

sonular almak olduka gtr, bunun yerine yarı denetimli denilen hibrit bir model kullanılır. Bu modelde az sayıda etiketlenmiř veri ve daha ok sayıda etiketlenmemiř veri birleřtirilerek byk veriler elde edilir (56). Derin ğrenme modellerini yeterince eğitmek iin uygun veri seti boyutu deėiřkendir ve iyi bir performans gstermesi iin byk miktarda veri setine ve iyi bir mimariye sahip olması gerekir. Byk miktarda veri istenmesine raėmen, yksek kalitede etiketlenmiř veri elde etmek maliyetli ve zaman alıcı olabilir. rneėin, 1000 vaka zerinde 20 dakikalık bir grnt segmentasyonu grevini tamamlamak, iki uzmanın 1 ay boyunca tam zamanlı alıřmasını gerektirebilir (55). Veri oėaltma (data augmentation) , kk bir veri setinin boyutunu yapay olarak bytmek iin kullanılabilir. Ama etiket atamalarının uygunluėunu deėiřtirmeyen verilere rastgele dnřmler uygulamaktır. Grntlere uygulanabilecek olası rastgele dnřmler arasında evirme, dndrme, teleme, yakınlařtırma, eėme ve elastik deformasyon yer alır. Veri oėaltma ile derin ğrenme modellerine sunulan grntlerin eėitim veri setinin boyutunu bytmek iin orijinal bir veri setinden grnt varyantları oluřturulur (57). Elde edilen veriler eėitim seti, validasyon (doėrulama) seti ve test seti olarak gruplandırılır.

Derin ğrenme algoritmalarının son zamanlardaki byk geliřimi ile derin ğrenme yntemleri; mamografide meme kanseri tespiti (6), BT’de karaciėer metastazlarının segmentasyonu (7), HRCT’de intertisiyel akciėer hastalıklarının sınıflaması (8), MR grntlemede beyin tmr sementasyonu (9) gibi birok tıbbi grntlemede kullanılmıřtır.

2.5.3. Transfer ğrenme

Transfer ğrenme nden eėitilmiř bir modelin yeni bir problem iin tekrar kullanımını saėlayan bir makine ğrenmesi metodudur (58). Daha nce benzer veya farklı grevlerde zaten eėitilmiř ve ğrenmiř bir modelin bilgilerinin yeni greve aktarılarak ğrenmenin iyileřtirilmesini saėlar. Bu yntem derin ğrenmede zellikle bilgisayarlı gr ve doėal dil iřleme grevlerinde bařlangı noktası olarak sık kullanılan yntemdir. Transfer ğrenme, ikinci grev modellenirken hızlı ilerleme ve iyileřtirilmiř model performansı saėlar (59). Karmařık modelleri eėitmek iin milyonlarca etiketli veri elde etmek ok zor olduėundan derin ğrenme modellerinde kullanıřlıdır. Transfer ğrenmede, bir temel aė nce bir temel veri kmesi ve grev zerinde eėitilir ve ardından ğrenilen zellikler yeniden tasarlanır veya bir hedef veri kmesi ve grev zerinde eėitilmek zere ikinci bir hedef aėa aktarılır. Bu aktarım, ilk grevden ğrenilen zellikler genel ise, yani hem temel hem de hedef grevler iin uygunsa alıřma eėilimindedir. Transfer ğrenme yalnızca ilk grevden ğrenilen zellikler genelleřtirilebilir


ise işe yarar. Parametre aktarımı, özellik çıkarma, ince ayar (fine-tuning) dahil olmak üzere farklı transfer öğrenme yöntemleri vardır. Parametre transferinde, bilgi model/parametre seviyesinde kaynak ve hedef öğrenici modellerinin paylaşılan parametreleri aracılığıyla aktarılır. Özellik çıkarımı, önceden eğitilmiş modeli sabit bir özellik çıkarıcı olarak kullanmayı ve çıkarılan özelliklerin üzerine yeni bir sınıflandırıcı eğitmeyi içerir. İnce ayar (fine-tuning), önceden eğitilmiş modeli öğrenilen özellikleri bozmamak için küçük bir öğrenme hızıyla yeni görev üzerinde eğitmeyi içerir.

2.5.4. Derin Öğrenme Tabanlı Nesne Tanıma Algoritmaları

Nesne tanıma, dijital görüntülerde ve videolarda belirli bir sınıftaki (insanlar, binalar veya arabalar gibi) nesnelerin örneklerini algılamakla ilgilenen, bilgisayar görüşü ve görüntü işleme ile ilgili bir bilgisayar teknolojisi (60). Nesne tanımanın iyi araştırılmış alanları arasında yüz tanıma ve yaya tanıma yer alır. Nesne tanıma algoritmaları, yalnızca görüntüde hangi nesnelerin veya yapıların bulunduğunu değil, aynı zamanda sınırlayıcı kutucuklarla o nesnenin görüntü içindeki tam konumlarını da tanımlar bakımından sınıflandırma algoritmalarından farklıdır (61). Konumlandırma ve tanıma aslında benzer görevlerdir: konumlandırma algoritmaları genellikle görüntüdeki tek bir nesneyi tanımlarken, nesne tanıma algoritmaları görüntüde bulunan bir veya daha fazla nesnenin varlığını ve konumunu bulabilir (Şekil 34'te gösterildiği gibi). Bu nedenle, bir nesne tanıma algoritması, görüntüde bulunan her nesne için bir sınırlayıcı kutu ve her bir sınırlayıcı kutuyla ilişkili olarak, içerdiği nesnenin türünü (genellikle nesnenin o sınıfa ait olma olasılığını gösteren bir değer) verir (61). Genel olarak, bilgisayarlı görü (computer vision) nesne tanıma algoritmaları iki adımı takip eder:

(1) İlk adımda ilgilenilen nesneyi içeren potansiyel yamaları (görüntü parçaları) bulmak için görüntüden birkaç yamanın çıkarılmasına atıfta bulunan bölge önerisi (regional proposal) yapılır. Tüm görüntü, belirli nesneleri içermesi en muhtemel bölgeleri bulmak için kayan pencere yaklaşımıyla veya özel bölge önerme algoritmalarıyla taranabilir ve yamalara bölünebilir.

(2) İkinci adımda ise belirli bir nesne içermeye olasılığına sahip sınırlayıcı kutular belirlemek için çıkarılan yamalar sınıflandırılır.



Şekil 34. Nesne tanıma algoritmalarının bir şekilde birden fazla nesneyi tanıyarak konumlandırmasına örnek

Nesne tanıma, görüntü algılama ve video gözetimi dahil olmak üzere bilgisayarlı görünün birçok alanında uygulamalara sahiptir. Görüntü açıklaması, araç sayımı (62), etkinlik tanıma (63), yüz tanıma, video nesnesi ortak bölümlleme gibi bilgisayarlı görü görevlerinde yaygın olarak kullanılır. Ayrıca, örneğin bir futbol maçı sırasında bir topun takibi, bir kriket sopasının hareketlerinin takibi veya bir videodaki bir kişinin takibi gibi nesnelerin takibinde de kullanılır.

Her bir nesne sınıfının, sınıflandırmaya yardımcı olan kendi özel özellikleri vardır, örneğin tüm daireler yuvarlaktır. Nesne tanıma bu özel özellikleri kullanır. Örneğin, daire ararken, bir noktadan (yani merkezden) belirli bir mesafede olan nesneler aranır. Benzer şekilde, kare ararken, köşelerde dik olan ve eşit kenar uzunluklarına sahip olan nesneler gereklidir. Yüz tanımlamada da benzer bir yaklaşım kullanılır, burada gözler, burun ve dudaklar bulunabilir, cilt rengi ve gözler arası mesafe gibi özellikler bulunabilir.

Nesne tanıma yöntemleri, genellikle sinir ağı tabanlı veya sinir ağı tabanlı olmayan derin öğrenme yaklaşımlarına ayrılır. Derin öğrenme bazlı sinir ağı tabanlı nesne tanıma algoritmaları tipik olarak konvolüsyonel sinir ağlarına (CNN) dayanır.

Sinir ağı tabanlı nesne tanıma algoritmaları arasında; Region proposal (R-CNN, Fast R-CNN, Faster R-CNN, cascade R-CNN), Single Shot MultiBox Detector (SSD) (64), You Only Look Once (YOLO) (65-67), Single-Shot Refinement Neural Network for Object Detection (RefineDet) (68), Retina-Net (69), Deformable convolutional networks (70) yer alır.


Derin öğrenme tabanlı nesne tanıma algoritmaları tek aşamalı ve çok aşamalı algoritmalar olarak ikiye ayrılır. Genel olarak, tek aşamalı algoritmalar hesaplama açısından verimliyken, iki/çok aşamalı algoritmalar daha iyi algılama performansına sahiptir. YOLO ailesi (65) ve tek atışlı çoklu kutu detektörü (single-shot multibox detector, SSD) basit model mimarilerine sahip iki klasik ve yaygın olarak kullanılan tek kademeli dedektörlerdir. Her iki mimari de sabit sayıda sınırlayıcı kutu ve bunların kutularda verilen sınıfların nesne örneklerinin varlığına karşılık gelen puanlarını üreten ileri beslemeli evrişimli (konvolusyonel nöral network, CNN) ağlara dayalıdır. Son tahminleri oluşturmak için maksimum olmayan bir bastırma adımı uygulanır (71).

Rutin tıbbi uygulamada, radyoloji, ultrasonografi, endoskopi, oftalmoloji ve patoloji gibi çeşitli alanlarda çok sayıda tıbbi görüntü üretilir. Klinik doktorlar bu görüntüleri taramak ve değerlendirmek için çok fazla zaman harcamak zorundadır. Derin öğrenme tabanlı nesne algılama algoritmaları meme kanseri, prostat kanseri, retinopati gibi birçok hastalıkta kullanılmış olup anatomik yapıları işaretleme, segmente etme gibi alanlarda da kullanılmıştır (61). Derin öğrenme; direkt radyografi, mamografi, BT, MRG veya USG gibi çeşitli görüntüleme yöntemlerinde şüpheli kitlelerin otomatik olarak lokalizasyonuna ve hatta bazen lezyonların iyi huylu veya kötü huylu olarak sınıflandırılmasına olanak tanıyarak radyologlara yardımcı olma ve görüntüleri değerlendirme sürelerini kısaltarak zaman kazandırma potansiyeline sahiptir.

3. GEREÇ VE YÖNTEM

Çalışmamızda İstanbul Bağcılar Eğitim ve Araştırması PACS ve HBYS sisteminden retrospektif olarak dahil edilen hasta verileri ve çalışmada bahsi geçen diğer açık kaynak radiopaedia.org verilerinin birlikte kullanılması için Sağlık Bilimleri Üniversitesi İstanbul Bağcılar Eğitim ve Araştırma Hastanesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu tarafından 22/12/2022 tarihli 2022/12/01/038 karar nolu etik kurul onayı alınmıştır.

Veri toplama sürecinden model eğitim ve değerlendirilmesine kadar olan yaklaşımlar Şekil 35 Şekil 35’te özetlenmektedir.



Şekil 35. Çalışma Diagramı

3.1. Verilerin Toplanması

Araştırmamız retrospektif olup 2016-2022 yılları arasında Bağcılar Eğitim ve Araştırma Hastanesi'nde HBYS (Hastane Bilgi Yönetim Sistemi) kayıtlarında mevcut direkt radyografi raporlarında fraktür tanımlanan 10 bin görüntü ve açık kaynak radiopaedia.org adresinde bulunan 7106 adet direkt radyografi görüntüsü ile toplam 17106 adet direkt radyografiyi içermektedir. Bağcılar Eğitim ve Araştırma hastanesinde elde edilen tüm direk radyografi görüntüleri SAMSUNG marka XGEO GC80 model, SG HEALTCARE marka JUMONG ve JUMONG M model, DRGEM marka XCSD-R1 ve TOPAZ 32D modelleri olan cihazlarla oluşturulmuştur ve hastane PACS sisteminde bulunmaktadır. Çalışmaya dahil edilen tüm veriler kişisel verilerin gizliliği prensibine bağlı kalınarak anonimize edilmiştir. Çalışmaya dahil edilme ve hariç tutulma kriterleri aşağıdaki gibidir:

Dahil edilme:

- ☐ Tüm yaş grupları
- ☐ Apendiküler İskelet Direkt radyografileri (El, El-Bilek, Kol, Ön Kol, Omuz, Dirsek, Ayak, Ayak Bileği, Kruris, Uyluk, Diz, Kalça ve Pelvis radyografileri)
- ☐ Direkt radyografi görüntülerinin hastanemiz PACS sisteminde bulunması (yalnızca hastane HBYS sisteminden dahil edilecek hastalar için geçerlidir).
- ☐ Yorumlamayı tamamen engelleyecek düzeyde artefakt olmaması

Hariç tutma:

- ☐ Aksiyel iskelet direkt radyografileri (Maksillofasyal, Kranial, Nazal, Lomber, Servikal, Torakal, Sakrum, Koksiks ve Akciğer Radyografileri)
- ☐ Yorumlamayı engelleyecek eksik –hatalı çekim
- ☐ Yorumlamayı tamamen engelleyecek düzeyde artefakt bulunması

3.2. Veri Setlerinin Hazırlanması


Araştırmayı yürüten radyolog tarafından dahil edilme ve hariç tutulma kriterleri göz önünde bulundurularak Bağcılar Eğitim ve Araştırma Hastanesi PACS sisteminden elde edilen 10 bin adet direkt radyografi görüntüsünden 4354 adet uygun görüntü seçilmiştir. Ayrıca radiopaedia.org internet sitesinden açık kaynak olarak paylaşılmış direkt radyografi görüntüleri

“fraktür” anahtar sözcüğü kullanılarak tespit edilmiş olup yine araştırmayı yürüten radyolog tarafından 7106 görüntü içerisinde dahil edilme ve hariç tutulma kriterlerine uygun biçimde 4632 adet görüntü seçilmiş olup toplam 8.986 adet görüntü veri setini oluşturmaktadır.

3.3. Görüntülerin Değerlendirilmesi ve İşaretlenmesi (Annotasyon)

Elde edilen görüntüler lokal bilgisayar ortamında Massachusetts Institute of Technology (MIT) lisanslı Intel®’e bağlı açık kaynak “Computer Vision Annotation Tool” (CVAT, www.cvat.ai) kullanılarak 5 yıl deneyimli bir radyolog tarafından işaretlenmiştir. İşaretlemelerde “bounding-box” yöntemi tercih edilmiştir. Bu yöntemde ilgili patolojiyi içerisine alacak şekilde görsel bir kutucuk oluşturulmaktadır ve bu kutucuğun koordinat verileri uygun bir formatta saklanabilmektedir. Görüntüde seçilebilen fraktür lokasyonu radyolog tarafından fraktürü tam içine alan sınırlayıcı kare kutucuk çizme yöntemi ile işaretlenmiştir. Bir görüntüde birden fazla fraktür bulunabileceği gibi fraktür içermeyen görüntüler de veri setinde mevcuttur. Aynı hastaya ait birden fazla projeksiyonu içeren görüntülerde yalnızca seçilebilen fraktür işaretlenmiş olup örneğin aynı hastanın AP radyografisinde seçilen fraktür hattı lateral radyografisinde seçilmiyorsa yalnızca fraktürün görüldüğü radyografide kırık kutucuk içerisine alınarak işaretlenmiştir. Ayrıca veri setinin dağılımını belirleyebilmek için işaretlemeler esnasında ilgili görüntülere anatomik lokasyonu belirtecek sınıflar atanmıştır. Bu sınıflar şu şekildedir: El, El Bilek, Ön Kol, Dirsek, Kol, Omuz, Ayak, Ayak Bileği, Kruris, Diz, Uyluk, Kalça, Pelvis.

İşaretlemeler kaydedilirken YOLO işaretleme formatı tercih edilmiştir. YOLO formatında, bir kutucuk dört adet koordinat benzeri değer ile temsil edilir $[x_merkez, y_merkez, genişlik, uzunluk]$. x_merkez ve y_merkez kutucuğun merkezinin normalize edilmiş koordinatlarıdır. Normalizasyon ilgili eksen değerinin görüntü boyutlarına bölünmesi ile (x merkez/görüntünün total genişliği, y merkez/ görüntünün total uzunluğu gibi) gerçekleştirilen bir işlemdir. Tariflenen genişlik ve uzunluk değerleri ise kutucuğun genişlik ve uzunluğunu ifade eder ve bunlar da ilgili eksenler ile normalize edilmiş değerlerdir (Şekil 36).



Şekil 36. Yolo işaretleme formatı. u : uzunluk, g : genişlik, y_m : y koordinatında kutucuk merkezi, x_m : x koordinatında kutucuk merkezi, x_{max} : x koordinatında görüntünün en geniş olduğu nokta, y_{max} : y koordinatında görüntünün en geniş olduğu nokta, kırmızı hat: temsili fraktür hattı.

3.4. Verilerin Ön İşlenmesi ve Veri Çoğaltımı

3.4.1. Ön İşleme

İşaretlenmiş olan görüntülerde model eğitimi öncesinde kontrast ile sınırlandırılmış adaptif histogram eşitleme (CLAHE) ön işleme metodu uygulanmıştır. Adaptif histogram eşitleme görüntü kontrastını iyileştirmekte kullanılan bir bilgisayar görüntü işleme tekniğidir. Adaptif metod sıradan histogram eşitlemeden farklı olarak görüntünün farklı bölgelerine karşılık gelen yerlerden çok sayıda histogramı işleyerek görüntüdeki yüksek ışık değerlerini tekrar dağıtır. Bu nedenle görüntünün her bir bölgesinde lokal kontrastı artırmak ve kenar keskinliğini güçlendirmekte uygun bir tercihtir. Yine de AHE görüntünün görece homojen bölgelerinde gürültüyü artırma eğilimi vardır. Bu problemin aşılmasında CLAHE

geliştirilmiştir. Bu yöntemde ise kontrast amplifikasyonu kısıtlanmaktadır böylelikle gürültü daha az oluşmaktadır. AHE ve CLAHE yöntemleri Pizer ve ark (1987) tarafından ilgili çalışmada detaylı olarak anlatılmıştır (72). Yöntemin görüntülere uygulanmasında python yazılım diline ait bir kütüphane olan “albumations (v1.3.0)” kullanılmıştır. CLAHE parametrelerinden “clip limit” değeri 7, “tile grid size” ise 11 olarak tercih edilmiştir.

3.4.2. Eğitim, Validasyon ve Test Veri Setlerinin Oluşturulması

Çalışmaya dahil edilen verilerin 7678 adeti eğitim, 854 adeti validasyon, 454 adeti test veri setine ayrılmıştır. Bu ayırmda veriler, anatomik lokasyon sınıfları ve fraktür varlığı-yokluğu göz önünde bulundurularak python yazılım dilinin açık kaynak bir kütüphanesi olan scikit-learn (v1.2.2) kullanılarak rastgele seçilmiştir. “StratifiedShuffleSplit” algoritması sayesinde eğitim, validasyon ve test veri setlerinin anatomik lokasyon ve fraktür bakımından dağılımları korunmuştur. Buna göre örneğin eğitim setinde el bilek radyografisi sayısının toplam eğitim seti sayısına oranı ile validasyon ve test veri setlerindeki el bilek radyografisi sayısının ilgili toplam validasyon ve test seti sayısına oranı aynı kalmaktadır.


3.4.3. Veri Çoğaltımı

Geliştirilecek olan modellerin genelleştirilebilirliğini artırmak ve eğitim sürecinde model ezberlemesi olarak da ifade edilen “overfitting” i engellemek için model eğitimi esnasında “online” olarak eğitim seti üzerinde veri çoğaltımı yapılmıştır (test veri setinde bu işlemler yapılmamıştır). Online veri çoğaltımı aşamasında ise “ rastgele hue-saturation-value değeri”, “translasyon”, “rastgele skala”, “rastgele vertikal çevirme”, “mozaik görüntü”, “mixup(karma) görüntü” kullanılmıştır.

3.5. Model Yapısı

YOLOv7, tek aşamalı bir gerçek zamanlı nesne tanıma algoritmalarındandır. YOLO ailesine 2022 Temmuz’da katılmıştır. YOLOv7 makalesine göre, bu model diğer YOLO modellerine kıyasla araştırmanın yapıldığı tarihe kadarki en hızlı ve en doğru gerçek zamanlı nesne tanıma algoritmasıdır (73).

YOLO mimarisi bir FCNN (Tam Evrişimli Sinir Ağı, Fully Convolutional Neural Network) olup şekilde gösterilmiştir (Şekil 37).



Şekil 37. YOLO network yapısı (Backbone: Model iskeleti, FPN: Feature Pyramide Network*, Concatenate: Birleştirme basamağı, filter size: filter büyüklüğü, in dim: girdi boyutu, out dim: çıktı boyutu, inject points: veri giriş noktaları, conv: konvolüsyon, upsample: üstel örnekleme, yolo loss: YOLO kayıp fonksiyonu, Cross Entropy Loss: Çapraz Entropi kayıp fonksiyonu, L1 loss: L1 norm kayıp fonksiyonu, Objectness loss: nesnellik kayıp fonksiyonu, Şekil <https://blog.roboflow.com/yolov7-breakdown/> adresinden alıntıdır. *Özellik Çıkarım Piramid Ağı)

YOLO yapısının 3 ana temel bileşeni vardır:

- Omurga(Backbone)
- Boyun(Neck)
- Kafa(Head)

Omurga, esas olarak bir görüntünün temel özelliklerini çıkarıp bu özellikleri boyun ve kafaya besleyerek iletir. Boyun, omurga tarafından çıkarılan özellik haritalarını toplar ve özellik piramitleri oluşturur. Son olarak, kafa ise nihai tespitlere sahip çıktı katmanlarından oluşur. YOLOv7, birkaç mimari reformu tanıtarak hızı ve doğruluğu artırır (74). Scaled (ölçekli) YOLOv4'e benzer şekilde, YOLOv7 omurgaları ImageNet ile önceden eğitilmiş omurgaları kullanmaz. Bunun yerine, modeller tamamen COCO veri kümesi kullanılarak eğitilir.

YOLOv4'ün bir uzantısı olan Scaled (ölçekli) YOLOv4 ile aynı yazarlar tarafından yazıldığı için benzerlikleri mevcuttur. YOLOv7 makalesinde aşağıdaki önemli değişiklikler tanıtılmıştır. (73).

- Mimari Reformlar
 - E-ELAN (Extended Efficient Layer Aggregation Network, Genişletilmiş Verimli Katman Toplama Ağı)
- Birleştirme Tabanlı Modeller için Model Ölçeklendirme Reformları
 - Eğitilebilir BoF (Bag of Freebies)
 - Planlanmış tekrar parametrelendirilen evrişim
 - Yedek kayıp fonksiyonu için kaba ve önder kayıp fonksiyonu için ince ayar

YOLOv7 mimarisi, YOLOv4, Ölçekli YOLOv4 ve YOLO-R'den türetilmiş olup bu modeller baz alınarak yeni ve gelişmiş bir model ortaya çıkarılmıştır.

E-ELAN, YOLOv7 omurgasındaki hesaplama bloğudur. Ağ verimliliği ile önceki araştırmalardan ilham alır. Herhangi bir nesne tanıma ve örnek segmentasyon görevi için basit ve standart bir eğitim iskeleti olarak YOLOv7'nin diğer mimarilerle karşılaştırıldığında temel farkı, YOLOv7'nin omurgasının genişletilmiş verimli katman toplama ağı (E-ELAN) ile DarkNet53'e dayanmasıdır. E-ELAN yapısı, eklenen özelliklerin kardinalitesini artırmak için grup evrişimini kullanır ve farklı grupların özelliklerini bir karıştırma ve birleştirme kardinalliği tarzında birleştirir. Bu tür bir işlem, farklı özellik haritaları tarafından öğrenilen özellikleri geliştirebilir ve parametrelerin ve hesaplamaların kullanımını geliştirebilir (75).

YOLOv7 modelinin tariflendiği orijinal araştırmadan elde edilen Tablo 3'te YOLOv7 ile diğer obje tanıma modelleri arasındaki farklar özetlenmiştir (73). Ayrıca bu tabloda COCO açık kaynak veri setinde elde edilen başarımlar bildirilmiştir. Biz araştırmamızda COCO veri setinde ön eğitilmiş YOLOv7-E6 modelini kullanarak transfer öğrenme uyguladık.

Tablo 3. Yolov7 model yapıları ve diğer modellere ait parametreler ve COCO veri seti başarımları

Model	#Param.	FLOPs	Size	AP ^{val}	AP ^{val}	AP ^{val}	AP ^{val}	AP ^{val}	AP ^{val} _L
YOLOv4	64.4M	142.8G	640	49.7%	68.2%	54.3%	32.9%	54.8%	63.7%
YOLOv4-u5 (r6.1)	46.5M	109.1G	640	50.2%	68.7%	54.6%	33.2%	55.5%	63.7%
YOLOv4-CSP	52.9M	120.4G	640	50.3%	68.6%	54.9%	34.2%	55.6%	65.1%

YOLOR-CSP	52.9M	120.4G	640	50.8%	69.5%	55.3%	33.7%	56.0%	65.4%
YOLOv7	36.9M	104.7G	640	51.2%	69.7%	55.5%	35.2%	56.0%	66.7%
YOLOR-CSP-X	96.9M	226.8G	640	52.7%	71.3%	57.4%	36.3%	57.5%	68.3%
YOLOv7-X	71.3M	189.9G	640	52.9%	71.1%	57.5%	36.9%	57.7%	68.6%
YOLOv4-tiny	6.1	6.9	416	24.9%	42.1%	25.7%	8.7%	28.4%	39.2%
YOLOv7-tiny	6.2	5.8	416	35.2%	52.8%	37.3%	15.7%	38.0%	53.4%
YOLOv4-tiny-3l	8.7	5.2	320	30.8%	47.3%	32.2%	10.9%	31.9%	51.5%
YOLOv7-tiny	6.2	3.5	320	30.8%	47.3%	32.2%	10.0%	31.9%	52.2%
YOLOR-E6	115.8M	683.2G	1280	55.7%	73.2%	60.7%	40.1%	60.4%	69.2%
YOLOv7-E6	97.2M	515.2G	1280	55.9%	73.5%	61.1%	40.6%	60.3%	70.0%
YOLOR-D6	151.7M	935.6G	1280	56.1%	73.9%	61.2%	42.4%	60.5%	69.9%
YOLOv7-D6	154.7M	806.8G	1280	56.3%	73.8%	61.4%	41.3%	60.6%	70.1%
YOLOv7-E6E	151.7M	843.2G	1280	56.8%	74.4%	62.1%	40.8%	62.1%	70.6%

3.6. Model Eğitim Süreci ve Doğrulanması

Model eğitim sürecinde kullanılan hiperparametreler Tablo 4'te belirtilmiştir. Model eğitiminde 1024x1024 girdi (input) piksel boyutu kullanılmıştır. Model 1 adet Nvidia RTX3090 24G ekran kartı kullanılarak eğitilmiştir. Eğitim süreci aktif olarak takip edilmiş olup model validasyon metriğinin (mAP50='mean average precision') daha fazla artış göstermediği aşamada eğitim durdurulmuş ve en yüksek mAP50 parametresine ulaşılan model test aşamasında kullanılmıştır. Model 'batch' büyüklüğü 8'dir. Model toplam 177 epoch eğitilmiştir. Model toplam eğitim süresi 1.21 gün (29 saat) olup 'epoch' başına eğitim ortalama 9.83 dk sürmüştür.

Tablo 4. Model eğitiminde kullanılan hiperparametreler ve ilgili açıklamaları

Hiperparametre	Açıklama	Hiperparametre	Açıklama
lr0: 0.001	Başlangıç öğrenme oranı (SGD=1E-2)	hsv_h: 0.0	Görüntü HSV-Hue çoğaltımı (fraksiyon)
lrf: 0.1	Final OneCycleLR öğrenme oranı (lr0 * lrf)	hsv_s: 0.0	Görüntü HSV-Saturation çoğaltımı (fraksiyon)
momentum: 0.937	SGD momentum	hsv_v: 0.0	Görüntü HSV-Value çoğaltımı (fraksiyon)
weight_decay: 0.0005	Optimizasyon algoritması ağırlık kayıp faktörü 5e-4	degrees: 30.0	Görüntü rotasyonu (+/- derece)
warmup_epochs: 3.0	Isınma 'epoch' sayısı	translate: 0.2	Görüntü translasyon (+/- fraksiyon)
warmup_momentum: 0.8	Isınma başlangıç momentumu	scale: 0.9	Görüntü skala (+/- kazanım)
warmup_bias_lr: 0.1	Isınma başlangıç bias öğrenme oranı	shear: 0.0	Görüntü shear (+/- derece)
box: 0.05	Kutucuk kayıp kazanımı (loss gain)	perspective: 0.0	Görüntü perspektif (+/- fraksiyon), aralık 0-0.001
cls: 0.3	Sınıf kayıp kazanımı (loss gain)	flipud: 0.5	Görüntü flip yukarı-aşağı (olasılık)
cls_pw: 1.0	Sınıf BCELoss pozitif ağırlık	fliplr: 0.5	Görüntü flip sol-sağ (olasılık)
obj: 0.7	Objeye kayıp kazanımı (loss gain) (pikseller ile orantılı)	mosaic: 1.0	Görüntü mozaikleştirme (olasılık)

obj_pw: 1.0	Obje BCELoss pozitif ağırlık	mixup: 0.15	Görüntü karma (olasılık)
iou_t: 0.20	IoU eğitim eşik değeri	copy_paste: 0.0	Görüntü kopyala yapıştır (olasılık)
anchor_t: 4.0	Çapalama (anchor) çoklu eşik değeri	paste_in: 0.0	Görüntü kopyala yapıştır (olasılık), (daha hızlı eğitim için 0 tercih edildi)
fl_gamma: 0.0	Fokal kayıp (focal loss) gamma	loss_ota: 0 .0	ComputeLossOTA kullanımı, (daha hızlı eğitim için 0 tercih edildi)

Validasyon ve test aşamasında her bir kutucuk tahmini kutucuk metriklerinden sıkça kullanılan mAP50, mAP50:95, kesinlik (pozitif prediktif değer), duyarlılık hesaplamaları ile değerlendirildi. Ayrıca görüntü bazlı olarak genel pozitiflik ve negatifliğe göre kesinlik, duyarlılık, özgüllük ve f1 skorları hesaplandı. Validasyon ve test verisetlerinde farklı model tahmin eşik değerleri kullanılarak yapılan tahminler üzerinde karışıklık matrisleri ('confusion matrix') elde edildi.

3.7. Model Çıktılarının Kıyaslanması


Test veri setinde model tahminleri yapılmıştır. Genel radyolojide 21 yıl deneyimli (C.V., RAD2) , 6 yıl deneyimli (M.K, RAD1) ve 3 yıl deneyimli (E.İ., RAD3) üç ayrı radyolog test veri setindeki görüntülerde fraktür varlığı veya yokluğu bakımından değerlendirme yapmıştır. Değerlendirme esnasında her görüntüde ilgili radyologlar önce model tahmini olmadan ham görüntü üzerinde fraktür var veya yok yorumu yapmış olup sonrasında model tahmini ilgili radyoloğa gösterilmiş ve model ile birlikte değerlendirme sonucu fraktür varlığı/yokluğu verisi elde edilmiştir. Model öncesi değerlendirme ve model ile birlikte yapılan değerlendirme birbiri ile kıyaslanmıştır.

3.8. İstatistiksel Analizler

Model başarımlarının değerlendirilmesinde mAP50, mAP50:95, kesinlik, duyarlılık metrikleri ölçülmüştür. Radyologlar arası uyum için Cohen's Kappa değeri elde edilmiştir. Model öncesi ve sonrası radyolog performansı arasındaki farkların değerlendirilmesi için McNemar testi uygulanmıştır. Sonuçların değerlendirilmesinde $p < 0.05$ istatistiksel anlamlı kabul edilmiştir.


4. BULGULAR

Araştırmamız dahilinde geliştirdiğimiz YOLOv7 otomatik nesne tanıma algoritma modelinde; sınırlayıcı kutucuk (bounding box) bazında etiketlenmiş olarak Bağcılar Eğitim ve Araştırma Hastanesi PACS sisteminden (Bağcılar veri seti) 4354 adet, açık kaynak radiopaedia.org internet sitesinden (Radiopaedia veri seti) 4632 olmak üzere toplam 8986 adet direkt radyografi görüntüsü yer almaktadır. Bağcılar veri setinde dahil edilen hastaların 2996 adeti erkek (%68,8), 1358 adeti kadınlardan (%31,2) oluşmaktadır (Şekil 38).




Şekil 38. Bağcılar veri seti cinsiyet dağılım grafiği

Bağcılar veri setine dahil edilen görüntülerin 3083'ü (%70.8) 21 yaş üstündeki hastalara, 1210'u (%27.8) 2-21 yaş aralığındaki hastalara, 61'i (%1.4) ise 2 yaş altındaki hastalara aittir. Hastaların yaş dağılım histogramı ve grafiği Şekil 39 ve Şekil 40'da gösterilmektedir.



Şekil 39. Bağcılar veri seti yaş dağılım histogramı




Şekil 40. Bağcılar veri setindeki hastaların yaş dağılım grafiği


Tüm veri setinde bulunan 8986 adet direkt radyografi görüntüsünün 6283 (%69.92) tanesinde fraktür bulunmakta olup 2703 (%30) adet görüntüde fraktür bulunmamaktaydı. Tüm veri setinde fraktür bulunan görüntülerin 3813 adeti Radiopaedia veri setine, 2470 adeti Bağcılar veri setine aitti. Eğitim veri setinde bulunan toplam 7678 adet direkt radyografi görüntüsünün 5365 adetinde, validasyon setindeki toplam 854 adet görüntülerin 597 (%69.9) adetinde, test veri setindeki 454 adet görüntülerin 321 (%70.7) adetinde fraktür bulunmaktaydı. Modelimizde bulunan veri setlerindeki fraktür sayıları Tablo 5’te belirtilmiştir.

Tablo 5. Veri Setlerindeki Fraktür Olan ve Olmayan Görüntülerin Sayıları				
	Kaynak	Toplam Sayı	Fraktür Olan Görüntü Sayısı	Fraktür Olmayan Görüntü Sayısı
Tüm Veri Seti	Radiopaedia	4632	3813	819
	Bağcılar	4354	2470	1884
Eğitim Veri Seti	Radiopaedia	4040	3297	743
	Bağcılar	3638	2068	1570
Validasyon Veri Seti	Radiopaedia	436	360	76
	Bağcılar	418	237	181
Test Veri Seti	Radiopaedia	156	156	0
	Bağcılar	298	165	133


Tüm veri setinde, eğitim veri setinde, validasyon veri setinde ve test veri setinde bulunan direkt radyografilerin anatomik lokasyonlarının Bağcılar ve Radiopaedia kaynağına göre dağılımları (Şekil 41. Tüm veri setindeki anatomik bölgelerin dağılımını gösteren bar grafiği Şekil 41, Şekil 42, Şekil 43, Şekil 44’te gösterilmektedir. Tüm veri setindeki direk radyografilerin 1881’i (%20.9) el bileği, 1442’si (%16) ayak bileği, 1108’i (%12.3) diz, 806’si (%9) ayak, 742’si (%8.3) el, 692’si (%7.7) dirsek, 562’si (%6.3) omuz, 489’u (%5.4) pelvis, 440’ı (%4.9) kruris, 407’i (%4.5) femur, 285’i (%3.2) ön kol, 105’i (%1.2) kol, 27’si (%0.3) koksofemoral direkt radyografi görüntülerinden oluşmaktadır.




Şekil 41. Tüm veri setindeki anatomik bölgelerin dağılımını gösteren bar grafiği



Şekil 42. Eğitim veri setindeki anatomik bölgelerin dağılımını gösteren bar grafiği




Şekil 43. Validasyon veri setindeki anatomik bölgelerin dağılımını gösteren bar grafiği




Şekil 44. Test veri setinde anatomik bölgelerin dağılımını gösteren bar grafiği

Şekil 45'te veri setlerine dahil edilen görüntülerin genişliklerinin (x ekseninde piksel cinsinden) histogram grafiği gösterilmektedir. Görüntüler arasında en küçük genişlik 237 piksel, en büyük genişlik 3040 piksele ulaşmakta olup median genişlik 1024 pikseldir.




Şekil 45. Tüm veri setine dahil edilen görüntülerin genişliklerinin (piksel) histogram grafiği

Şekil 46'te veri setlerine dahil edilen görüntülerin yüksekliklerinin (y ekseninde piksel cinsinden) histogram grafiği gösterilmektedir. Görüntüler arasında en küçük yükseklik 274 piksel, en büyük genişlik 3072 piksele ulaşmakta olup median yükseklik 1024 pikseldir.




Şekil 46. Tüm veri setine dahil edilen görüntülerin yüksekliklerinin (piksel) histogram grafiği

Şekil 47’de veri setlerine dahil edilen görüntülerin toplam piksel sayılarının karekökleri alınarak oluşturulmuş histogram grafiği gösterilmektedir. Görüntüler arasında toplam piksel karekök sayısı en küçük 492, en büyük 3039 olup median piksel karekök sayısı 1024’tür. Toplam piksel karekökü mevcut görüntülerin boyutlarının en/boy oranından bağımsız olarak standart bir şekilde ifade edilebilmesi için hesaplanmıştır.




Şekil 47. Tüm veri setine dahil edilen görüntülerin toplam piksel sayılarının karekökleri alınarak oluşturulmuş histogram grafiği

Şekil 48’de veri setlerine dahil edilen görüntülerdeki kutucuk işaretlemelerin toplam piksel sayılarının karekökleri alınarak oluşturulmuş histogram grafiği gösterilmektedir. Kutucuk işaretlemeleri arasında toplam piksel karekök sayısı en küçük 5, en büyük 1262 olup median piksel karekök sayısı 73’tür. Toplam piksel karekökü mevcut kutucukların boyutlarının en/boy oranından bağımsız olarak standart bir şekilde ifade edilebilmesi için hesaplanmıştır.




Şekil 48. Tüm veri setine dahil edilen görüntülerde bulunan kutucuk işaretlemelerin toplam piksel sayılarının karekökleri alınarak oluşturulmuş histogram grafiği

Şekil 49’de model eğitim süreci boyunca her bir epoch’ta eğitim ve validasyon aşamalarında kayıp fonksiyonları ve validasyon aşamasındaki kesinlik, duyarlılık ve ortalama kesinlik (mAP) değerlerindeki değişimler gösterilmektedir. Buna göre modelin belirgin düzeyde bir ezberleme (overfitting) yapmadığı ifade edilebilir. Validasyon aşamasında en yüksek elde edilen kesinlik değeri % 76.6, duyarlılık değeri % 52.5, güven eşik değeri 0.5 iken ortalama kesinlik (mAP@0.5) değeri % 60, güven eşik değeri 0.5-0.95 arasında iken ortalama kesinlik (mAP@0.5-0.95) değeri % 28.5 idi.




Şekil 49. Model eğitimi süresince eğitim ve validasyon aşamalarında kutucuk kayıp (box loss), nesnesellik kayıp (objectness loss) ile validasyon aşamasında kesinlik, duyarlılık, ortalama kesinlik (mAP) değerlerinin epochlar arasındaki değişimi.


Validasyon ve test setinde model tahminlerine ait F1 skoru, kesinlik ve duyarlılığın güven eşik değeri ile ilişkisi ve kesinlik-duyarlılık arasındaki ilişki sırasıyla Şekil 50, Şekil 52, Şekil 53, Şekil 51’da gösterilmektedir.




Şekil 50. Validasyon (sol) ve test (sağ) veri setinde güven eşik değeri (confidence) ve F1 skoru ilişkisi



Şekil 52. Validasyon (sol) ve test (sağ) veri setinde güven eşik değeri (confidence) ve kesinlik (precision) ilişkisi



Şekil 51. Validasyon (sol) ve test (sağ) veri setinde güven eşik değeri (confidence) ve duyarlılık (recall) ilişkisi




Şekil 53. Validasyon (sol) ve test (sağ) veri setinde duyarlılık(recall) ve kesinlik (precision) ilişkisi


Test setinde farklı güven eşik değerlerindeki model tahminlerinin görüntü bazlı fraktür varlığı/yokluğu açısından performans metrikleri Tablo 6’de gösterilmiştir. Test setinde [mAP@0.5](#) değeri 0.58 olarak ölçülmüştür. AUC-ROC skoru ve F1 skoru en yüksek güven eşik değeri 0.05 iken elde edilmiş olup sırasıyla 0.89 ve 0.90 olarak hesaplanmıştır. Güven eşik değeri 0.05 iken duyarlılık 0.91, kesinlik 0.88, özgüllük ise 0.72’dir.

Tablo 6. Test setinde farklı güven eşik değerlerindeki model tahminlerinin görüntü bazlı fraktür varlığı/yokluğu açısından performans metrikleri

Güven değeri	eşik	Doğruluk(Accuracy)	Duyarlılık (Sensivite)	Kesinlik (Precision)	Özgüllük (Spesifite)	F1 Skoru	AUC ROC
conf_0.05		0,859031	0,915888	0,888218	0,721805	0,90184	0,89777
conf_0.1		0,828194	0,831776	0,917526	0,819549	0,872549	0,872719
conf_0.15		0,817181	0,785047	0,947368	0,894737	0,858603	0,859228
conf_0.2		0,784141	0,728972	0,955102	0,917293	0,826855	0,836589
conf_0.25		0,744493	0,666667	0,959641	0,932331	0,786765	0,810168
conf_0.3		0,720264	0,626168	0,966346	0,947368	0,759924	0,793819
conf_0.35		0,685022	0,570093	0,973404	0,962406	0,719057	0,770185
conf_0.4		0,292952	0	0	1	0	0,5
conf_0.45		0,621145	0,476636	0,974522	0,969925	0,640167	0,726876
conf_0.5		0,292952	0	0	1	0	0,5
conf_0.55		0,548458	0,367601	0,983333	0,984962	0,535147	0,677769
conf_0.6		0,511013	0,314642	0,980583	0,984962	0,476415	0,651688
conf_0.65		0,473568	0,255452	1	1	0,406948	0,627726
conf_0.7		0,292952	0	0	1	0	0,5
conf_0.75		0,372247	0,11215	1	1	0,201681	0,556075
conf_0.8		0,292952	0	0	1	0	0,5
conf_0.85		0,299559	0,009346	1	1	0,018519	0,504673
conf_0.9		0,292952	0	0	1	0	0,5
conf_0.95		0,292952	0	0	1	0	0,5



Şekil 54. Test veri setinde fraktür varlığı/yokluğu açısından radyologların model öncesi ve model ile birlikte değerlendirmelerine ait karıştırma (confusion) matrisleri



Şekil 55. Test veri setinde model tahminlerinin fraktür varlığı/yokluğu açısından karıştırma matrisleri (güven eşik değeri 0.05).

Şekil 54’de test veri setinde radyologların model öncesi ve model ile birlikte, Şekil 55’de ise güven eşik değeri 0.05 iken modelin fraktür tespit performanslarına ait karıştırma matrisleri gösterilmektedir.


Tablo 7’de Test setinde genel radyolojide 6 yıl deneyimli (RAD1), 21 yıl deneyimli (RAD2) ve 3 yıl deneyimli (RAD3) radyologların model öncesi ve model ile birlikte fraktür varlığı/yokluğuna dair değerlendirmelerin performans metrikleri ve model öncesi-sonrası arasında istatistiksel anlamlılık değerleri gösterilmektedir. Buna göre model ile birlikte radyolog kesinlik değeri model öncesine göre RAD1’de % 0.8, RAD2’de % 0.02, RAD3’te % 1.1 artış göstermiştir; duyarlılık değeri RAD1’de % 9, RAD2’de % 7.8, RAD3’te % 5 artış göstermiştir. Doğruluk değerleri model ile birlikte model öncesine göre RAD1’de % 5.2, RAD2’de % 7.3, RAD3’te % 11.4; F1 skoru RAD1’de % 5.8, RAD2’de % 4.7, RAD3’te % 4 artış göstermiştir. Yapılan McNemar analizinde tüm değerlendiricilerde model öncesi ve model ile birlikte değerlendirme arasında model ile birlikte değerlendirme lehine istatistiksel olarak anlamlı fark bulunmaktadır ($p < 0.000$).

Tablo 7. Model öncesi (pre) ve model ile birlikte (post) yapılan incelemelerde radyologların performans metrikleri

	RAD1	RAD2	RAD3
Kesinlik (pre)	0,9482072	0,9766537	0,9574468
Kesinlik (post)	0,9569892	0,9787234	0,9681275
Duyarlılık (pre)	0,741433	0,7819315	0,7009346
Duyarlılık (post)	0,8317757	0,8598131	0,7570093
Doğruluk (pre)	0,7885463	0,8325991	0,7665198
Doğruluk (post)	0,8546256	0,8876652	0,8105727
Özgüllük (pre)	0,9022556	0,9548872	0,924812
Özgüllük (post)	0,9097744	0,9548872	0,9398496
F1 skoru (pre)	0,8321678	0,8685121	0,8093525
F1 skoru (post)	0,89	0,9154229	0,8496503
P değeri	<0.000	<0.000	<0.000
McNemar İstatistiği	26,28	16,46	13,88

Değerlendiriciler arası uyum için yapılan analizde, Cohen's Kappa değerleri RAD1 ve RAD3 arasında 0.68, RAD2 ile RAD3 arasında 0.65, RAD1 ve RAD2 arasında 0.71 ölçülmüştür. Tüm değerlendiriciler arasında önemli derecede uyuşma vardır.

4.1. Vaka Örnekleri




Şekil 57. A) Sol el 2. distal falanksta bifid falanks görünümü mevcut. Veri seti işaretlenirken radyolog tarafından fraktür yok olarak değerlendirilmişti, hastanın eski görüntülerinde de aynı görünüm mevcuttu. B). Model tahmini bu varyasyonu sınırlayıcı kutucuk ile işaretlemiş ve yanlış pozitif sonuç vermiştir. Test veri setini değerlendiren 3 radyologtan 2'si de aynı görüntüye fraktür olarak sınırlayıcı kutucuk koymuştur.



Şekil 56. Sağ el oblik grafide sağdaki original görüntüde 1. distal falanksta bifid falanks izlenmekte ve 4. falanks bazisinde nondeplase fraktür hattı gözleniyor. Sağdaki model tahmininde modelimiz sadece fraktür olan yere kutucuk yerleştirip doğru tahmin gerçekleştiriyor. Bifid falanksı fraktür olarak yanlış değerlendirmiyor ve epifiz hatlarını kolaylıkla normal olarak değerlendiriyor.



Şekil 58. Sağ el radyografisinde original görüntüde (soldaki) 4. orta falanks bazisinde hafif deplase fraktürü modelimizin de fraktür olarak doğru tamin ettiği (sağdaki görüntü) izlenmekte




Şekil 59. Modelin fraktür yok olarak doğru tahmin ettiği bir el direkt radyografisi. Epifiz hatları açık olan hastanın el radyografisinde fraktür bulunmamakta olup model tahmini de bu radyografiyi normal olarak değerlendirmiştir (Sağdaki radyolog değerlendirmesi, soldaki model tahmini).




Şekil 60. Soldaki original sağdaki model tahmini bulunan uyluk direkt radyografileri. Modelimiz pelvisteki epifiz hatlarından bazılarını fraktür olarak değerlendirdi (Yanlış pozitif model tahmini).



Şekil 61. Radius ve ulna distalinde torus fraktürleri bulunan (siyah ok). Sağdaki görüntüde modelimiz torus fraktürlerini yanlış negatif olarak normal olarak değerlendirmekte



Şekil 62. Üstteki görüntüler original görüntüler, alttaki görüntüler model tahmin görüntüleri. Modelimiz 5. Metatars apofizini fraktür olarak değerlendirip sınırlayıcı kutucuk yerleştirmiş, görüntü alanındaki kalkaneal apofizi ve epifiz hatlarını normal olarak değerlendirmiş. Bu görüntü test setinden bir örnek olup test veri setini değerlendiren 3 radyologtan 2'si de burayı yanlış pozitif fraktür olarak değerlendirmiştir.




Şekil 64. Pelvis direkt radyografilerine örnekler. Soldaki görüntüler original, sağdaki görüntüler ise model tahmin görüntüleri. Sağ alttaki model tahmin görüntüsünde modelimiz 2 adet sınırlayıcı kutucuk koyarak iki farklı yeri fraktür olarak değerlendirmiştir. Sakrum düzeyindeki kolon gazına kutucuk koyarak yanlış pozitif olarak işaretlemiştir. Bu radyografideki sol iliak kemikteki fraktür olan yer doğru olarak tahmin edilmiş, ancak kutucuk kemik dışı alanda olup doktorlar tarafından kolaylıkla değerlendirilebilir niteliktedir.




Şekil 63. Modelin yanlış pozitif olarak değerlendirdiği görüntülere örnekler. Modelimiz atel bulunan görüntüleri, kıyafet-damar yolu vb cilt/cilt altında normal görüntülerden farklı olarak kontrast farkı bulunan görüntüleri tahmin ederken yanlış pozitif sonuçlar elde etti. Bu yanlış pozitif görüntülerin çoğundaki fraktür kutucukları kemik dışı alanda olduğu için hekimler tarafından zorlayıcı olmadan değerlendirilebilir.




Şekil 66. Original (A ve C) ve model tahmin görüntüleri (B ve D). Modelin fraktür olarak doğru tahmin ettiği el radyografilerine örnekler



Şekil 65. Modelin fraktür olarak doğru tahmin ettiği radyografilere örnekler



Şekil 67. Modelin fraktür olarak doğru tahmin ettiği direkt grafilere örnekler



Şekil 69. Modelin fraktür olarak doğru tahmin ettiği direkt grafilere örnekler. Original görüntüler (A ve C) ve modelin fraktür olarak doğru tahmin ettiği görüntüler (B ve C).



Şekil 68. Modelin fraktür olarak doğru tahmin ettiği direkt grafilere örnekler. Original görüntüler (A ve C) ve modelin fraktür olarak doğru tahmin ettiği görüntüler (B ve C).

5. TARTIŞMA

Çekilen görüntü sayıları ve hasta sayılarına kıyasla radyologların sayısı kıyaslanamayacak ölçüde azdır ve bu görüntüleri değerlendirmek radyologların iş yükü kapasitelerinin üzerindedir. Bu nedenle tüm dünyada radyologlar büyük miktarda tıbbi görüntü verisi ile boğulmuş durumdadırlar. Sonuç olarak, bu alanda radyologlar için yardımcı teknolojilere ihtiyaç duyulmaktadır. Radyologların iş yükünü azaltmak ve daha doğru tanı koymalarına yardımcı olmak için Bilgisayar Destekli Tespit ve Teşhis (Computer Aided Detection and Diagnosis, CAD) geliştirilmekte ve ikinci bir okuyucu olarak yaygın bir şekilde kullanılmaktadır. CAD'in aşağıdaki dört hedefe ulaşmaya çalıştığı belirtilmiştir: radyologların performansını iyileştirmek, zamandan tasarruf etmek, iş akışına sorunsuz bir şekilde entegre olmak ve ihmal edilebilir artan maliyetlere sahip olmak (76). Derin öğrenme yöntemlerinin ortaya çıkmasıyla, CAD algoritmaları radyologlara klinik ortamda yardımcı olma konusunda umut vaat etmektedir. Son yıllarda derin öğrenme algoritmaları ile sinir ağları (CNN) tabanlı derin öğrenme yöntemleri; kanser tahmini (77), beyin tümörü segmentasyonu (78) , pulmoner nodül tespiti (79) ve beyin görüntü analizine (80) başarıyla uygulanmıştır. CAD'in temel konsepti, radyolojik tanının doğruluğunu ve tutarlılığını iyileştirerek ve ayrıca görüntü okuma süresini azaltarak radyologların görüntü yorumlamasına yardımcı olmak için ikinci bir görüş olarak bir bilgisayar çıktısı sağlamaktır.

Kemik fraktürleri acil servislerde çok yaygın görülen ortopedik travmatik acil sebeplerinden biridir. Kırık tespitinde direkt radyografi ilk başvurulması gereken tanı yöntemidir. Direkt radyografilerde otomatik fraktür tespiti ile görüntüyü değerlendiren hekime hem zaman tasarrufu hem de Bilgisayar Destekli Tespit ve Teşhis (Computer Aided Detection and Diagnosis, CAD) ile karar destek mekanizması sağlanabilir. Böylelikle yanlış veya eksik tanı nedeniyle ortaya çıkabilecek sonuçlar önlenir. 8968 adet direkt radyografi görüntüsü içeren, YOLOv7 nesne tanıma algoritması modelini kullanarak fraktür tespit etmeye çalıştığımız araştırmamızda hem çocuk hem de erişkinlerde görülebilecek apendiküler iskeletin tüm kırık çeşitlerini; küçük/büyük, deplase/nondeplase, atel-fiksator-metal var/yok gibi herhangi bir ayırım yapmadan direkt grafilerde fraktür yorumlamaya çalışan uzman/pratisyen tüm branş hekimlerinin karar destek mekanizmasında yardımcı olmak, hekimlere zaman kazandırmak, yanlış negatif tanı oranını ve bu nedenle olabilecek komplikasyonları azaltmayı hedefledik.

Fırat Hardalaç ve ark.larının yaptığı Gazi Üniversitesi Hastanesi acil birimi arşivindeki 542 adet el bilek direkt radyografi görüntüsü ile Huawei Türkiye destekli çalışmasında (81); 10'dan fazla derin öğrenme tabanlı nesne tanıma algoritması kullanılmış olup bu derin öğrenme algoritmalarından birkaç derin öğrenme modelinin kombinasyonu (ensemble) olan WFD-1, WFD-2, WFD-3, WFD-4, WFD-5, WFD-C adında 6 farklı fraktür tanıma algoritması geliştirilmiştir ve bu yeni modellerin arasında en başarılı model en yüksek mAP50 skoru 0.8639 ile WFD-C ile bulunmuştur. Çalışmada tüm veriler bizim araştırmamızda olduğu gibi COCO transfer öğrenme ile ön eğitime sokulmuştur, yine bizim de kullandığımız veri ön işleme, veri çoğaltımı, tüm verilerin CLAHE ile normalizasyonu aşamaları, eğitim-validasyon-test veri setlerinin hazırlanması benzerdir. Ancak bu çalışmaya sadece el bileği kemiklerinden radius ve ulna kırıkları dahil edilmiş olup küçük ve hekimler tarafından grafide fraktür tespiti oldukça zorlayıcı olabilen karpal kemikler (skafoïd, lunat, psiform, triquetrum, trapezoid, trapezoideum, hamatum, kapitatum) dahil edilmemiştir. Çalışmada sadece 542 adet aynı cihaza ait direkt radyografi görüntüsü kullanılmış olup görüntülerdeki tek heterojenite el bileğinin sağ veya sol el bileği grafileri olarak taraf heterojenitesidir. Veri seti toplam 245 ayrı hastaya ait görüntülerden oluşmakta olup bu hastaların sadece 21(%7.63) tanesi 12 yaş altındadır. Bu da çalışmada çok az sayıda epifiz ve apofiz içeren görüntü mevcut olduğunu, modelin veya hekimlerin fraktür ile karıştırabildiği normal oluşumların oldukça az sayıda bulunduğunu göstermektedir. Ayrıca çalışmaya negatif yani fraktür olmayan grafiler dahil edilmemiştir. Biz ise modelimizi tüm grafilerin %30'u normal grafi, olacak şekilde fraktür içermeyen grafilerle de eğittik. El bilek direkt radyografilerinde en sık kırık rastlanan karpal kemik skafoïd kemiktir (82). Bu kırıkların %40'a yakını ilk değerlendirmede gözden kaçır (83). Atlanan skafoïd kırıkları osteoartrit, kaynamama, yanlış kaynama, avasküler nekroz gelişebilir (84). Biz modelimizde bu fraktür çeşidini de bulmayı hedefledik.

Guan ve ark.'ının 2020 yılında yaptığı çalışmada, deneyimli radyologlar tarafından 'normal veya anormal' olarak işaretlenmiş açık kaynak veri seti olan 'MURA(Musculoskeletal radiograph, kas iskelet radyografisi)' veri seti içerisinde bulunan 4000'e yakın kol direkt radyografisi ile 2 aşamalı R-CNN derin öğrenme modeli geliştirilmiş olup modelin fraktür tespitinde AP değeri % 62.04 olarak bulunmuştur (85). Bu çalışmada humerus, dirsek ve ön kola ait 3392 adet fraktür içeren direkt radyografi görüntüsünün tamamı veri seti olarak kullanılmış olup geriye kalan 612 fraktür içeren görüntü de test seti verisi olarak kullanılmış ve normal görüntüler veri setine dahil edilmemiştir. Çalışmaya dahil edilen görüntüler Linyi People's Hastanesi'nden 3 ayrı radyolog tarafından işaretlenmiştir. MURA veri seti, Stanford

Makine Öğrenme Grubu tarafından Ocak 2018'de yayınlanan en büyük radyografik görüntü veri setlerinden biridir ve omuz, humerus, dirsek, önkol, bilek, el ve falanksalar dahil olmak üzere üst ekstremitenin 40.895 adet radyografik görüntüsünü içerir (86). Çalışma içerisinde yer alan radyologlara göre yanlış pozitif tahminlerin varlığı önemsiz olarak değerlendirilmiştir ve radyologlar hızlı bir şekilde bu yanlış pozitif tahminleri kolaylıkla ayırt edebilmiştir. Çalışmada yer alan radyologlara göre hastanenin radyoloji bölümündeki tıbbi uyuşmazlıkların %90'ının fraktür tespitindeki eksiklerden kaynaklı olduğu belirtilmiştir. Çalışmanın model performansını sınırlandıran faktörlerin veri setindeki görüntü çözünürlüğü kalitesi ve özel tip fraktürler olduğu düşünülmüştür. Derin öğrenme tabanlı nesne tanıma algoritmalarında modelin doğru çalışması için görüntü çözünürlüğü kalitesi önemli rol oynadığı, MURA veri setindeki görüntü çözünürlüklerinin 600x600 piksele dek düşük olduğu ve çalışmada yer alan radyologların bulunduğu hastanenin Digital Radyografi cihazlarının görüntü çözünürlüklerinin 3000x1500 piksel olduğu ifade edilmiştir. Bizim de araştırmamızda kullandığımız veri setimizde yer alan görüntüler oldukça heterojen olup görüntü piksel sayısı karekökleri 492 ile 3039 piksel arasında değişmektedir. Bu çalışmada yer alan radyologlar tarafından ifade edilen ve modelin kaçırdığı fraktürleri barındıran yanlış negatif görüntülerin nedenleri saklı fraktür hattı, çok küçük fraktür hatları, atel barındıran direk radyografiler veya birbiri üstüne gelen-örtüşen (overlapping) fraktürleri barındıran radyografiler olarak belirtilmiştir. Biz de benzer şekilde çok küçük fraktürlerin yer aldığı görüntülerde ve atel içeren görüntülerde model tahminlerimizde yalancı pozitif ve negatifler tespit ettik. Bizim modelimiz özellikle atel içeren görüntülerde yer alan kemik fraktürlerini bulmakla birlikte bu sabitleyicilerde olan kırılmaları da fraktür olarak tespit etmiştir. Ancak bu durum her hekim tarafından kolaylıkla ayırt edilebilir ve model tahmini olarak işaretli alanın özellikle kemik dışındaki bölgelerde gerçekleşmesi halinde karar mekanizmasını etkilemeyeceği aşıkardır.

Guan ve ark.ları 2019 yılında yaptıkları çalışmada 3842 uyluk kırığını içeren direkt radyografi görürüntülerini, FPN (Feature Pyramid Network) çerçevesindeki omurga ağını yeni tasarladıkları DCFPN (Dilated Convolutional Feature Pyramid Network) ismini verdikleri omurga ağı ile değiştirerek yeni bir derin öğrenme modeli eğitmişlerdir (87). Araştırmacılar bu modelin başarısının mAP değerinin FPN'ye kıyasla %3.9 artarak 82,1'e ulaştığını göstermişlerdir. Veri setindeki 3842 görüntünün 358 tanesi test veri setine ayrılmış olup tüm görüntüler Linyi People's Hastanesi radyologları tarafından işaretlenmiştir. Çalışmada kullanılan tüm direkt radyografi görüntüleri bu hastanede bulunan tek bir cihazdan elde edilmiştir. Araştırmacılar bu çalışmada DCFPN'nin pratik klinik ortamlarda güçlü bir

potansiyelle uygulanabileceğini göstermişlerdir. Yine de çalışmada yanlış pozitif model tahminlerinin mevcut olduğu fakat bu görüntülerin çalışmada yer alan radyologlar tarafından kolaylıkla ayırt edilebilir nitelikte olduğu belirtilmiştir. Yüksek mAP değerine rağmen geliştirilen model yine de bazı kırıkları gözden kaçırmıştır ve bunun nedenleri arasında fraktürlerin küçük olması, saklı kırıkların olması veya eğitim setinde bazı kırık çeşitlerinden az sayıda görüntü bulunması sayılmıştır. Bizim çalışmamızda da yanlış pozitif model tahminlerinin radyologlar tarafından kolaylıkla ayırt edilebildiği gözlenmiş olup yine yanlış negatif model tahminleri Guan ve ark.'ın çalışmasında tariflediğine benzer sebeplerle ortaya çıkmaktadır. Yine de radyologların model tahminleri ile birlikte yaptığı değerlendirmelerde fraktür tespitinde duyarlılık ve özgüllüklerinin düzeylerinin anlamlı olarak arttığını yaptığımız analizlerde ortaya koyduk. Yanlış negatif model tahminlerinin daha ileri araştırmalarla ve daha geniş veri setleri kullanılarak azaltılabileceğini düşünmekteyiz.

Wang ve ark.ları iki aşamalı R-CNN ağı ve ParallelNet adını verdikleri TripleNet omurga ağı kullandıkları metod ile direkt grafilere uyuk fraktürlerinin tespitinde %87.8 AP50 değerini elde etmişlerdir. Çalışmada kullanılan 3842 görüntünün 358 adeti test veri seti olarak geri kalanı ise eğitim veri seti olarak ayrılmıştır. Veri seti boyutunun fraktür öğrenmesi için yetersiz olduğu düşünülüp modeller ResNet-101 modelinin önceden eğitilmiş modeli ile transfer öğrenme yolu ile eğitilmiştir. Biz de çalışmamızda model konverjansını hızlandırmak, bölgesel minimalardan kaçınmak ve nihayetinde başarıyı artırmak için COCO veri setinde eğitilmiş YOLOv7 ön modellerinden transfer öğrenme ile modelimizi eğittik.

Hayashi ve ark.ları ticari bir yazılım programı olan BoneView™ isimli yapay zeka programını kullanarak pediatrik yaş grubunda (2-21 yaş) bizim çalışmamıza benzer şekilde appendiküler iskelette farklı anatomik bölgeleri içeren 300 adet direkt radyografi görüntülerini fraktür tespiti için derin öğrenme tabanlı nesne tanıma algoritmalarını kullanarak eğittikleri retrospektif çalışmada, radyologlar tarafından işaretlenen 300 adet görüntünün hasta başına duyarlılığı (tüm kırıkların tanımlandığı hastaların oranı) ve kırık başına duyarlılığı (tüm kırıklar arasında yapay zeka tarafından tanımlanan kırıkların oranı), hasta başına özgüllüğü ve hasta başına yanlış pozitif oranını hesaplamış ve bu oranları şu şekilde bulmuşlardır: Tüm kırıklar için hasta başına duyarlılık %91,3, hasta başına özgüllük %90, kırık başına hassasiyet %92,5 ve kırığı olmayan hastalarda hasta başına yanlış pozitif oranı %0,11 (88). Bu araştırmadaki 300 adet görüntünün 150 tanesinde fraktür bulunmakta 150 tanesinde ise fraktür bulunmamaktadır, el/bilek, dirsek/üst kol, omuz/klavikula, ayak/ayak bileği, kruris/diz olarak sınıflandırılan 5 ayrı bölgenin her birinden 60'ar adet görüntü kullanılmıştır. Çalışmaya göre BoneView™ derin

öğrenme algoritması pediatrik yaş grubu kırık tespitinde tüm anatomik lokalizasyonlar ve avulsion kırıkları hariç tüm fraktür çeşitlerinde yüksek performansla kullanılabilir sonucuna varılmıştır. Çalışmada yapay zeka modeli olarak Facebook tarafından açık kaynak olarak geliştirilen derin öğrenme modeli Detectron2 (89) kullanılmıştır.

Thian ve ark.larının, bir hastenenin acil birime başvuran 7356 farklı hastaya ait 7295’u AP ve 7319’u lateral toplam 14614 el bilek direkt radyografi görüntüsünü derin öğrenme tabanlı nesne tanıma algoritması ve CNN alt tiplerinden olan Inception-ResNet Faster R-CNN mimarisi kullanarak direkt grafilerde Radius ve Ulna fraktürünü tespit etme amacıyla yaptıkları çalışmada, görüntüler 3 ayrı radyolog tarafından ‘bounding-box’ kullanılarak işaretlenmiş olup elde edilen görüntülerin %90’ı eğitim seti, %10’u ise validasyon seti olarak ayrılmıştır (90). Model eğitildikten sonra yine acil servise başvuran ardışık 524 ayrı hastanın toplam 1048 adet ayrı el bilek direkt radyografi grafileri test veri seti olarak kullanılmıştır. Modelin sensitivitesi ve spesifitesi her görüntü için sırasıyla %95.7 ve %82.5 olarak bulunmuştur. Test verisindeki modelin fraktür olarak işaretlediği toplam 646 görüntünün 100 tanesinin yanlış pozitif olduğu ifade edilmiştir. Model başarısının nondeplase ve minimal deplase olan fraktürlerde daha düşük olduğu ve pediatrik grup hastalarda epifiz ve apofizlerin yanlış pozitif olarak işaretlenebildiği belirtilmiştir. Yine pediatrik yaş grubunda görülen Salter-Harris tip 1 fraktürlerin model tarafından tanınmadığı belirtilmiştir. Araştırmalarında yer alan ve özellikle hem AP hem de lateral grafide de görüntüye giren atelin görüntü kalitesini bozup artefaktlara neden olarak yanlış negatif veya pozitif sonuçlara yol açabileceği de not edilmiştir. Birden fazla anatomik bölgede yapılacak olan çalışmalarda model başarısının düşük olabileceği belirtilmiştir. Bu çalışma el bilek grafilerinde fraktür tespit etme amacıyla yapılsa da sadece radius ve ulna fraktürlerini tespit etmeyi hedeflemiştir ve çalışmaya el bileğindeki karpal kemik fraktürleri dahil edilmemiştir. Araştırma verileri sadece acil kliniğe başvuran hastaları içermekte olup çalışma verilerinde farklı cihaz veya farklı merkez kaynaklı görüntü heterojenitesi bulunmamaktadır. Çalışmamızda birden fazla anatomik bölge eğitim, validasyon ve test veri setlerine dahil edilmiş olup Thian ve ark.larının yaptığı çalışmada ifade edildiği gibi farklı anatomik bölgelerle birlikte eğitilen modellerde başarımlar düşmektedir ve her anatomik bölgeden yeterli sayıda veri toplama ihtiyacı ortaya çıkmaktadır. Ayrıca bu çalışmayla benzer şekilde atel içeren görüntülerin fraktür tespitini zorlaştırdığını, küçük fraktürlerin atlanabildiğini ve pediatrik yaş grubundaki apofiz-epifizlerin yanlış pozitif sonuç verdiği, Salter-Harris tip I fraktürlerinin model tarafından atlanabileceği sonucuna vardık. Modelimizde ayrıca başka

yanlış pozitif sonuç verebilen normal oluşumlar bulunmakta olup bunları limitasyonlar olarak açıkladık.

Wu ve ark.larının Resnext-101+FPN mimarisini baz alarak oluşturdukları ve FAMO (Feature Ambiguity Mitigate Operator) adını verdikleri yeni nesne tanıma algoritması kullanarak farklı vücut bölümlerini içeren toplam 9040 direkt radyografi görüntüsünde fraktür tespit etme amacıyla yaptıkları çalışmada; mAP (ortalama kesinlik) değeri %77.4, görüntü başına sensitivite %77.5, spesifite %93.4, AUC ise %86.5 olarak bulunmuştur (91). 1651 adet el, 1302 adet el bilek, 406 adet dirsek, 1580 adet pelvis, 948 adet diz, 1180 adet ayak bileği, 1277 adet ayak direkt grafisi elde edilmiş olup radyologlar tarafından görüntüler 'bounding-box' yöntemi ile işaretlenmiştir. Farklı her bir bölge için model başarısına bakılmıştır. Modelin başarısının en yüksek pelvis grafilerinde olduğu; dirsek, omuz ve diz grafilerinde model başarısının daha düşük olduğu sonucuna varılmış ve farklı bölgelerdeki başarımın ilgili anatomik lokasyona ait veri sayısı ile orantılı bir şekilde değişiklik gösterdiği düşünülmüştür. Çalışmanın limitasyonları bazı vücut bölümlerinden derin öğrenme modellerinin eğitimi için yetersiz sayıda veri olması ve tek merkezli-homojen bir veri setlerinin olması olarak yorumlanmıştır. Çalışma için seçilen verilerin yaş dağılımlarından ve veri setindeki dahil edilme veya edilmeme kriterlerinden bahsedilmemiştir. Bizim çalışmamızda kullandığımız veriler hibrit olup farklı cihaz kaynaklarından elde edilmiştir. Bu limitasyonu ortadan kaldırmamıza rağmen araştırmamız sonucunda, Wu ve ark.'ın çalışmasına benzer şekilde, anatomik lokasyonlara ait veri sayısı ile modellerin bu bölgelerdeki başarı düzeyini ilişkili olarak değerlendirdik. Buna göre veri sayısı daha fazla olan anatomik bölgelerde model başarımı artmakta olup literatür bilgileri de bunu desteklemektedir.

Xue ve ark.larının 3067 adet el grafisindeki fraktürleri tespit etmek amacıyla Faster R-CNN derin öğrenme tabanlı nesne tanıma algoritmasını GA (guadided anchor)_Faster R-CNN modeli olarak kullandıkları çalışmada mAP(ortalama kesinlik) değeri %70.7 ve F-1 skoru %86.6 olarak bulunmuştur (92). Görüntülerin 2453 tanesi eğitim setine dahil edilip 614 tanesi test veri seti olarak kullanılmıştır ve radyologlar tarafından işaretlenmiştir. Bu görüntüler haricinde ayrıca radyologlar tarafından işaretlenmeyen 275 ayrı bir test seti elde edilmiş olup model bu veri ile denenmiştir ve daha sonra bu görüntüler radyologlar tarafından kontrol edilmiştir. Modelin bu veri setindeki doğruluğu %97 olarak bulunmuş olup model toplam 275 görüntüden 13 tane fraktürü içeren 8 adet görüntüyü yanlış yorumladığı görülmüştür. Xue ve ark.ları yaptıkları bu araştırma sonucunda bu nesne tanıma modelinin klinik uygulamalarda kullanılabilecek büyük bir potansiyel taşıdığına ulaşmışlardır. Yine çalışmada el

radyografilerinde yer alan eklem aralıklarının model tarafından yanlış pozitif olarak değerlendirilebileceğinden ve genel nesne tanıma algoritmalarının medikal görüntülerde kullanılmasının veri seti yetersizliği ve küçük fraktürlerin olması nedeniyle oldukça zorlayıcı olduğunu belirtmişlerdir. Çalışma tek merkezli retrospektif olup veri setleri aynı radyografi cihazına aittir, bizimki gibi heterojen olmayıp homojendir. Çalışmada sadece el radyografileri kullanılmıştır. El bileği kırıkları veri setinde mevcut değildir yine veri setinde yer alan görüntülerin yaş dağılımlarından veya çalışmaya dahil edilme-edilmeme kriterlerinden bahsedilmemiştir. Biz de çalışmamızda bazı eklem aralıklarının model tarafından yanlış pozitif olarak değerlendirildiği sonucuna vardık; fakat bizim çalışmamızda eğittiğimiz modelin küçük boyuttaki fraktürleri büyük boyutlardaki fraktürler kadar başarılı tahmin ettiğini gözlemledik. Bunun tüm veri setine her türlü boyuttaki ve yeterince küçük boyuttaki çok sayıda direkt radyografi grafisini de dahil etmiş olmamızla ilişkili olduğunu düşünmekteyiz.

Oka ve ark.larının 18 yaşın üstündeki 369 farklı hastanın 369 AP el bilek grafisi ve 360 lateral el bilek grafisi ile yaptıkları ve distal radius fraktürlerini CNN olarak VGG16 modeli ile tespit ettikleri çalışmada, modelin AP grafilerde sensitivite ve spesifitesi sırasıyla 95 ± 3.1 ve 97 ± 2.6 olarak bulunmuştur (93). Yapılan çalışmaya dahil edilen direkt radyografi görüntülerinin sadece belirgin yer değiştirmiş olan akut kırıkları içeren grafiler olduğu ve nondeplase kırıkları veri setinde kullanmadıkları belirtilmiştir. Modelin 18 yaş altındaki hastalarda epifiz hatları kapanmadığı için bu bölgeleri fraktür olarak tespit ettiğini ve bu hasta grubunda modelin çalışmadığını açıklamışlardır. Biz ise modelimizi daha küçük bir veri seti ile ilk defa eğitirken benzer şekilde epifiz hatlarının model tarafından yanlış pozitif fraktür olarak değerlendirildiğini gözlemledik ve epifiz hatları açık olan daha fazla görüntü ile modelimizi eğittiğimizde ve veri seti sayısını arttırdığımızda bu yanlış pozitifliğin oldukça azaldığını gözlemledik. Modelimiz nihai olarak yine de bazı epifiz hatlarını kırık olarak tahmin etmiştir (Şekil 60'da örnek gösterildiği gibi) ve bu yanlış pozitif tahminlerin model veri setine daha fazla ve yeterli sayıda 18 yaş altı hasta görüntülerini dahil ederek önlenebileceğini düşünmekteyiz.

Ma ve ark.larının yaptığı 112 tanesi Radiopaedia websitesinden elde edilen toplam 3053 adet direkt grafi ile Faster R-CNN ve CrackNet yöntemlerini uygulayarak yaptıkları 2 aşamalı fraktür tespit çalışmasında; model performansı Radiopaedia test veri setinde %88.3 doğruluk , %88 kesinlik, % 87.5 recall, %88.2 F-1 değeri olarak bulunmuş olup hastaneden elde ettikleri test veri setinde bu değerleri sırasıyla %90.1, %89.7, %90.4, %90.1 olarak bulmuşlardır (94). Test veri seti toplam 1052 görüntüden oluşmakta olup bunların 526 tanesinde fraktür

bulunmakta geri kalanında fraktür bulunmamaktadır. Test veri setindeki görüntülerin 112 tanesi Radiopeadia websitesinden oluşmakta olup bunların da 56 tanesi fraktürlü geri kalanı fraktür olmayan normal görüntülerden oluşmaktadır. Farklı kaynak test veri setleri arasındaki model başarı farkı nedenleri açıklanmamıştır. Bu araştırmada önce 20 farklı kemik (pelvis, femur, patella, klavikula, tibia, fibula gibi) fraktürden bağımsız olarak bölge tespit amacıyla Faster R-CNN ile işaretlenmiş olup daha sonra bu kemikleri öğrenen model üstüne; araştırmacıların fraktür hattına spesifik olduğunu belirttikleri, CrackNet ismini verdikleri farklı bir model ile fraktür hatlarını işaretlemek amacıyla yeniden radyologlar tarafından işaretlenmiştir. Yaptıkları çalışmada CrackNet'in fraktür hattı tespitindeki başarısını oldukça yüksek bulmuşlardır fakat yine görüntülerin veri setlerinde dâhil edilip edilmeme kriterlerinden ve direkt grafilerin yaş dağılımlarından bahsedilmemiştir. Bizim çalışmamız gibi bir el, el bileği gibi tek bölgeye spesifik fraktür tespit etmeyi amaçlamayıp global, her bölge için kullanılabilecek gerçekçi bir model geliştirmeyi amaçlamışlardır.

Lindsey ve ark.ları 18 farklı ortopedist tarafından işaretlenen, içersinde 34.990 adet AP ve lateral el bilek grafisi barındıran toplam 135 bin 845 adet farklı vücut bölgelerini içeren direkt grafi radyografilerini kullanarak eğittikleri (Modifiye U-Net kullanarak) semantik segmentasyon modelinin acil serviste çalışan klinisyenler tarafından el bilek radyogfailerinde fraktür tespit etme spesifitesini %11 arttırarak bu modelle klinisyenlerin grafileri yanlış değerlendirme oranlarının ortalama %47 azalttığı sonucuna varmışlardır (95). Böylece derin öğrenme yöntemleri ile, direkt radyografide fraktür tespiti açısından alanında uzman olan hekimlerin işaretlemeleriyle eğitilen yapay zeka modellerinin acilde çalışan hekimlere destek sağlayabileceğini göstermişlerdir. Biz de çalışmamızda, semantik segmentasyon yöntemi ve işleme maliyeti daha yüksek olan bir “encoder-decoder” mimarisinden farklı olarak çalışma maliyeti daha düşük olan ve daha hızlı çalıştığı bilinen nesne tanıma yöntemine dayalı YOLOv7 mimarisini tercih ettik ve tüm doktorların modelimizi kullanarak direkt radyografilerde fraktür tespit edebilme başarısını arttırmayı ve yanlış veya geç tanı sonrası hastalarda oluşabilecek osteoartit, osteonekroz, non-union fraktür, eklem hareket kısıtlılığı gibi geri dönüşü olmayan komplikasyonları azaltmayı, hekimlere tanı koymada zaman kazandırmayı amaçladık.

Hzic ve ark.ları pediatrik yaş grubu el bilek radyografilerinde nesne tanıma algoritması YOLOv4 modelini kullanarak fraktür tespit ederek bu modelin radyologlardan daha iyi performans ve tahminde bulunduğu sonucuna ulaşmışlar (96). Ayrıca bu çalışmada nesne tanıma algoritması olan YOLOv4 modelinin direkt radyografilerde fraktür tespit etmede, Lindsey ve ark.larının kullandığı U-Net tabanlı segmentasyon (95) yaklaşımından daha iyi bir

model olduđu ifade etmişlerdir. Çalışma veri setini pediatrik yaş grubu hastalarına ait toplam 19.700 adet el bilek direkt radyografisi oluşturmakta olup bu görüntülerin 7119'u fraktür içermeyen normal radyografilerdir. Görüntüler radyologlar tarafından 'bounding-box' yöntemi ile işaretlenmiştir. Eğitim setine 15.900, validasyon setine 1950, test1 setine 1950, test2 setine 200 adet görüntü ayrılmıştır. Test2 veri seti 100 adet fraktür içeren 100 adet ise fraktür içermeyen el bilek grafisi mevcut olup bu test seti radyologlar ve model performansı karşılaştırması için kullanılmıştır. Bu test seti ile YOLOv4 modelinin performansı ile radyologların performansı ve model destekli radyolog performansı ile model desteksiz radyolog performansı kıyaslanmıştır. Model desteği ile radyolog başarısının arttığı ve istatistiksel olarak anlamlı fark olduğu sonucuna varılmıştır. Biz de araştırmamızda benzer şekilde model desteği ile radyolog başarısının arttığı ve istatistiksel olarak anlamlı fark olduğu sonucuna vardık.

Araştırmamızda bazı limitasyonlar bulunmaktadır. Çalışmamızda modelimiz ve görüntüleri değerlendiren radyologlar hastaların tıbbi geçmişi veya klinik muayane bulguları olmadan yalnızca görüntü okuma becerilerine göre değerlendirme yapmıştır. Fraktür tespitinde hastanın kliniği çok önemli rol oynar; fakat radyologların bu klinik bilgilere erişiminin bazen kısıtlı olduğu durumlara da rastlanır. Daha sonra yapılacak olan otomatik fraktür tespit çalışmalarında daha doğru sonuçlar almak için hasta kliniği korelasyonu da modellere eklenebilir. Aksesuar kemikler, Salter-Harris Tip 1 ve 5 kırıklar, bipartite patella, bipartite skafoid, apofizler, cleft epifiz, bifid falanks, pelvis ossifikasyon merkezleri, radial gaga, stres kırığı, torus kırığı, bükülme kırığı gibi kırık hattının seçilemediği veya direkt radyografilerde kırıkla karışabilen varyasyonlar/oluşumlar bulunduğu model tahmin başarımları düşmektedir. Sonraki çalışmalarda özellikle bu durumları ayırt etmek için özel veri setleri ile modeller geliştirilebilir. Modelimizin kırık tespit ettiği fakat aynı görüntülerde kırık bulunmayan bazı alanları (fiksator kırıkları, atel/tespitteki kırık hatlarına benzer hatlar gibi) da kırık olarak sınırlayıcı kutucuk koyarak tahmin ettiği bazı görüntüler modelimizin duyarlılık, kesinlik, özgüllük ve F1 skoru yüksek olmasına rağmen mAP değerlerinin düşük olmasını açıklamaktadır.

Modelimizin gerçekçi olması ve klinik pratikte uygulanabilir olması için çalışmamıza dahil ettiğimiz görüntüler atel-fiksator-metal içeren direkt radyografi görüntülerini de barındırmaktadır. Bildiğimiz kadarıyla çalışmamız literatürdeki hem çocuk hem de erişkinlerde apendiküler iskelette, direkt radyografilerde nesne tanıma algoritması kullanarak fraktür tespit etmeye çalışan ilk araştırmadır. Ayrıca bölgeden bağımsız olarak direkt radyografilerde YOLOv7 modelini kullanarak fraktür tespiti yapan literatürdeki ilk çalışmadır.

6. SONUÇ

Kemik fraktürleri acil servislerde çok yaygın görülen ortopedik travmatik acil sebeplerinden biridir. Travma sonrası kırık tespitinde direkt radyografi ilk başvurulması gereken tanı yöntemidir. Bazı fraktürlerin direkt radyografideki tespiti hekimler için oldukça güç ve zaman alıcıdır. Direkt radyografilerde gözden kaçan kırıklar malpraktis davalarının büyük bir bölümünü oluşturur.

Sonuç olarak, geliştirdiğimiz derin öğrenme tabanlı nesne tanıma algoritmasının radyologların teşhis performanslarını iyileştirdiğini ve tüm apendiküler iskelet kemik fraktürlerinin direkt radyografilerde lokalize etmede zaman verimliliğini arttırdığını gösterdik. Algoritmamızın acil servislerde ve radyoloji birimlerinde klinik pratikte uygulanabilip hekimlere kolaylık sağlayabileceğini düşünüyoruz. Literatürdeki diğer çalışmalara benzer şekilde model ile birlikte direkt radyografilerde fraktür tespitinde radyologların duyarlılık ve doğruluklarının önemli ölçüde arttığını istatistiksel olarak tespit ettik. Ayrıca araştırmamıza katılan radyolog deneyimlerine göre modelimizin fraktür tespitinde direkt radyografi değerlendirmesi yapan radyologlara zaman kazandırdığını gözlemledik.

Daha önce yapılan benzer çalışmalardan farklı olarak YOLOv7 nesne tanıma algoritmasını kullandığımız araştırma; hem çocuk hem de erişkinlerde görülebilecek apendiküler iskeletin tüm kırık çeşitlerini küçük/büyük, deplase/nondeplase, atel-fiksator-metal var/yok ayrımı yapmadan direkt radyografilerde fraktür tespiti yapan literatürdeki ilk çalışmadır.

KAYNAKÇA

1. Robbins, S. L., & Kumar, V. (2008). Robbins temel patoloji:(basic pathology). Nobel Tıp Kitabevi.
2. Tzelepi, V., Tsamandas, A. C., Zolota, V., & Scopa, C. D. (2009). Bone anatomy, physiology and function. Bone Metastases: A translational and clinical approach, 3-30.
3. Gökmen, F. G. (2003). Sistematik Anatomi. İzmir Güven Kitabevi.
4. HT, S. (2013). Kas iskelet sisteminin değerlendirilmesinde radyolojik görüntüleme yöntemleri. TOTBİD Dergisi, 12(1), 1-6.
5. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. nature, 521(7553), 436-444.
6. Becker, A. S., Marcon, M., Ghafoor, S., Wurnig, M. C., Frauenfelder, T., & Boss, A. (2017). Deep learning in mammography: diagnostic accuracy of a multipurpose image analysis software in the detection of breast cancer. Investigative radiology, 52(7), 434-.
7. Drozdal, M., Chartrand, G., Vorontsov, E., Shakeri, M., Di Jorio, L., Tang, A., ... & Kadoury, S. (2018). Learning normalized inputs for iterative estimation in medical image segmentation. Medical image analysis, 44, 1-13.
8. Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. IEEE transactions on medical imaging, 35(5), 1207-1216.
9. Havaei, M., Guizard, N., Larochelle, H., & Jodoin, P. M. (2016). Deep learning trends for focal brain pathology segmentation in MRI. Machine learning for health informatics: state-of-the-art and future challenges, 125-148.
10. Guly, H. R. (2001). Diagnostic errors in an accident and emergency department. Emergency Medicine Journal, 18(4), 263-269.
11. Berlin, L. (2001). Malpractice issues in radiology-Defending the" missed" radiographic diagnosis. American Journal of Roentgenology, 176(2), 317-322.
12. Wei, C. J., Tsai, W. C., Tiu, C. M., Wu, H. T., Chiou, H. J., & Chang, C. Y. (2006). Systematic analysis of missed extremity fractures in emergency radiology. Acta Radiologica, 47(7), 710-717.
13. Guly, H. R. (2001). Diagnostic errors in an accident and emergency department. Emergency Medicine Journal, 18(4), 263-269.
14. Williams, S. M., Connelly, D. J., Wadsworth, S., & WILSON, D. J. (2000). Radiological review of accident and emergency radiographs: a 1-year audit. Clinical radiology, 55(11), 861-865.
15. Petinaux, B., Bhat, R., Boniface, K., & Aristizabal, J. (2011). Accuracy of radiographic readings in the emergency department. The American journal of emergency medicine, 29(1), 18-25.
16. Pinto, A., Reginelli, A., Pinto, F., Lo Re, G., Midiri, F., Muzj, C., ... & Brunese, L. (2016). Errors in imaging patients in the emergency setting. The British journal of radiology, 89(1061), 20150914.
17. Brooks, A., Holroyd, B., & Riley, B. (2004). Missed injury in major trauma patients. Injury, 35(4), 407-410.

18. Kalmet, P. H., Sanduleanu, S., Primakov, S., Wu, G., Jochems, A., Refaee, T., ... & Poeze, M. (2020). Deep learning in fracture detection: a narrative review. *Acta orthopaedica*, 91(2), 215-220.
19. Yoon, A. P., Lee, Y. L., Kane, R. L., Kuo, C. F., Lin, C., & Chung, K. C. (2021). Development and validation of a deep learning model using convolutional neural networks to identify scaphoid fractures in radiographs. *JAMA network open*, 4(5), e216096-e2160.
20. Blüthgen, C., Becker, A. S., de Martini, I. V., Meier, A., Martini, K., & Frauenfelder, T. (2020). Detection and localization of distal radius fractures: Deep learning system versus radiologists. *European journal of radiology*, 126, 108925.
21. Chung, S. W., Han, S. S., Lee, J. W., Oh, K. S., Kim, N. R., Yoon, J. P., ... & Kim, Y. (2018). Automated detection and classification of the proximal humerus fracture by using deep learning algorithm. *Acta orthopaedica*, 89(4), 468-473.
22. Kitamura, G., Chung, C. Y., & Moore, B. E. (2019). Ankle fracture detection utilizing a convolutional neural network ensemble implemented with a small sample, de novo training, and multiview incorporation. *Journal of digital imaging*, 32, 672-677.
23. Badgeley, M. A., Zech, J. R., Oakden-Rayner, L., Glicksberg, B. S., Liu, M., Gale, W., ... & Dudley, J. T. (2019). Deep learning predicts hip fracture using confounding patient and healthcare variables. *NPJ digital medicine*, 2(1), 31.
24. Tuncel, E. (2008). *Klinik Radyoloji (Genişletilmiş 2. Baskı)*. Nobel & Güneş Tıp Kitabevi.
25. Kaya, T. (2017). *Radyografinin Temel Prensipleri ve Radyografik Yorumda Temel İlkeler*. Trd Seminerleri; 5: 1-22.
26. Oyar, O. (1998). *Radyolojide Temel Fizik Kavramlar*. Nobel Tıp Kitabevleri.
27. Oyar, O., & Gülsoy, U.K. (2003). *Tıbbi Görüntüleme Fiziği*. SDÜ Tıp Fakültesi.
28. Carlton, R. R., Adler, A. M., & Faulkner, W. H. (2013). *Radiographic imaging: concepts and principles*. Delmar Cengage Learning. basım yeri bilinmiyor : Delmar/Cengage Learning.
29. Harvey, C. J. (2008). *Principles of radiology. Surgery (Oxford)*, 26(6), 235-238.
30. National Aeronautics and Space Administration, Science Mission Directorate. (2010). *X-Rays*. Retrieved [insert date - e.g. August 10, 2016].
31. Kaya, T. (2008). *Kas İskelet Yumuşak Doku Radyolojisi*. Nobel & Güneş Kitabevi.
32. Clarke, B. (2008). Normal bone anatomy and physiology. *Clinical journal of the American Society of Nephrology*, 3(Supplement 3), S131-S139.
33. Huang, Y. Z., Xie, H. Q., & Li, X. (2020). *Encyclopedia of Bone Biology*.
34. Betts J.G., Young K.A., Wise J.A.,...& DeSaix P. (2022). *Anatomy and Physiology 2e*. Houston, Texas: OpenStax. Retrieved from <https://openstax.org/books/anatomy-and-physiology-2e>.
35. Paulsen, F., & Waschke, J. (2016). *Sobotta Atlas of Human Anatomy, Vol. 1, Head, Neck, Upper Limb*. Urban & Fischer Verlag/Elsevier GmbH.
36. Hansen, J. T. (2021). *Netter's Clinical Anatomy-E-Book*. Elsevier Health Sciences.

37. Keats, T. E., & Anderson, M. W. (2012). Atlas of Normal Roentgen Variants That May Simulate Disease: Expert Consult-Enhanced Online Features and Print. Elsevier Health Sciences.
38. Timins, M. E. (1999). Osseous anatomic variants of the wrist: findings on MR imaging. *AJR. American journal of roentgenology*, 173(2), 339-344.
39. Coskun, N., Yuksel, M., Cevener, M., Arican, R. Y., Ozdemir, H., Bircan, O., ... & Sindel, M. (2009). Incidence of accessory ossicles and sesamoid bones in the feet: a radiographic study of the Turkish subjects. *Surgical and radiologic anatomy*, 31, 19-24.
40. Kalantari, B. N., Seeger, L. L., Motamedi, K., & Chow, K. (2007). Accessory ossicles and sesamoid bones: spectrum of pathology and imaging evaluation. *Applied Radiology*, 36(10), 28.
41. Yeung, A. Y., & Garg, R. (2022). Anatomy, Sesamoid Bones. In StatPearls [Internet]. StatPearls Publishing.
42. Chen, W., Cheng, J., Sun, R., Zhang, Z., Zhu, Y., Ipaktchi, K., & Zhang, Y. (2015). Prevalence and variation of sesamoid bones in the hand: a multi-center radiographic study. *International Journal of Clinical and Experimental Medicine*, 8(7), 11721.
43. Verma, R., & Singh, J. P. (2022). Magnetic resonance imaging in stress fractures: making a correct diagnosis. *Indian Journal of Musculoskeletal Radiology*, 4, 49.
44. Berger, F. H., de Jonge, M. C., & Maas, M. (2007). Stress fractures in the lower extremity: the importance of increasing awareness amongst radiologists. *European journal of radiology*, 62(1), 16-26.
45. Karen R., Jean-François C., Karl J., Rachel M. M. (2021). Grainger & Allison's Diagnostic Radiology E-Book. 74 Paediatric Musculoskeletal Trauma and the Radiology of Nonaccidental Injury and Paediatric Fractures, Elsevier Health Sciences.
46. Kliegman, R. M., Behrman, R. E., Jenson, H. B., & Stanton, B. M. (2007). Nelson textbook of pediatrics e-book. Elsevier Health Sciences.
47. Malik, M., Demos, T. C., Lomasney, L. M., & Stirling, J. M. (2016). Bowing fracture with literature review. *Orthopedics*, 39(1), e204-e208.
48. Vergara-Amador, E., Herrera, D. D., & Moreno, L. A. (2016). Radiographic features of the development of the anterior tibial tuberosity. *Radiología (English Edition)*, 58(4), 294-300.
49. Ovalle, William K.; Nahirney, Patrick C. (2007). Netter's essential histology : with Student consult online access (1st ed.). Philadelphia, Pa.: Elsevier Saunders.
50. Salter, R. B., & Harris, W. R. (1963). Injuries involving the epiphyseal plate. *JBJS*, 45(3), 587-622.
51. Brent Harrison, R., & Keats, T. E. (1980). Epiphyseal clefts. *Skeletal Radiology*, 5, 23-27.
52. Lawson, J. P. (1985). Symptomatic radiographic variants in extremities. *Radiology*, 157(3), 625-631.
53. McArthur, T. A., Pitt, M. J., Garth Jr, W. P., & Narducci Jr, C. A. (2016). Pellegrini–Stieda ossification can also involve the posterior attachment of the MPFL. *Clinical Imaging*, 40(5), 1014-1017.
54. A. M. Turing (1950) Computing Machinery and Intelligence. *Mind* 49: 433-460.
55. Chartrand, G., Cheng, P. M., Vorontsov, E., Drozdal, M., Turcotte, S., Pal, C. J., ... & Tang, A. (2017). Deep learning: a primer for radiologists. *Radiographics*, 37(7), 2113-2131.

56. Kingma, D. P., Mohamed, S., Jimenez Rezende, D., & Welling, M. (2014). Semi-supervised learning with deep generative models. *Advances in neural information processing systems*, 27.
57. Roth, H. R., Shen, C., Oda, H., Oda, M., Hayashi, Y., Misawa, K., & Mori, K. (2018). Deep learning and its application to medical image segmentation. *Medical Imaging Technology*, 36(2), 63-71.
58. Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* (pp. 242-264). IGI global.
59. Yang, Q., Zhang, Y., Dai, W., & Pan, S. J. (2020). *Transfer learning*. Cambridge University Press.
60. Dasiopoulou, S., Mezaris, V., Kompatsiaris, I., Papastathis, V. K., & Strintzis, M. G. (2005). Knowledge-assisted semantic video object detection. *IEEE Transactions on Circuits and Systems for Video Technology*, 15(10), 1210-1224.
61. Chen, Y. W., & Jain, L. C. (2020). *Deep learning in healthcare*. Cham: Springer.
62. A. Alsanabani, A., A. Ahmed, M., & M. Al Smadi, A. (2020, December). Vehicle counting using detecting-tracking combinations: A comparative analysis. In *2020 The 4th International Conference on Video and Image Processing* (pp. 48-54).
63. Wu, J., Osuntogun, A., Choudhury, T., Philipose, M., & Rehg, J. M. (2007, October). A scalable approach to activity recognition based on object use. In *2007 IEEE 11th international conference on computer vision* (pp. 1-8). IEEE.
64. Liu, S., Cong, Y., Wang, D., Sun, Y., Deng, L., Liu, Y., ... & D'Angelo, R. (2014). és mtsai. Breast cancer stem cells transition between epithelial and mesenchymal states reflective of their normal counterparts. *Stem cell reports*. Elsevier, 2, 78-91.
65. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
66. Redmon, J., & Farhadi, A. (2017). YOLO9000: better, faster, stronger. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 7263-7271).
67. Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2021). Scaled-yolov4: Scaling cross stage partial network. In *Proceedings of the IEEE/cvf conference on computer vision and pattern recognition* (pp. 13029-13038).
68. Zhang, S., Wen, L., Bian, X., Lei, Z., & Li, S. Z. (2018). Single-shot refinement neural network for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4203-4212).
69. Lin, T. Y., Goyal, P., Girshick, R., & He, K. P. Dollár.(2017). Focal loss for dense object detection. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, PP (99), 2999-3007.
70. Zhu, X., Hu, H., Lin, S., & Dai, J. (2019). Deformable convnets v2: More deformable, better results. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 9308-9316).

71. Kaur, A., Singh, Y., Neeru, N., Kaur, L., & Singh, A. (2021). A survey on deep learning approaches to medical images and a systematic look up into real-time object detection. *Archives of Computational Methods in Engineering*, 1-41.
72. Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., ... & Zuiderveld, K. (1987). Adaptive histogram equalization and its variations. *Computer vision, graphics, and image processing*, 39(3), 355-368.
73. Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *arXiv preprint arXiv:2207.02696*.
74. Gillani, I.S., Munawar, M.R., Talha, M., Azhar, S., Mashkoo, Y., uddin, M.S., & Zafar, U. (2022). Yolo5, Yolo-x, Yolo-r, Yolo7 Performance Comparison: A Survey. *Artificial Intelligence and Fuzzy Logic System*.
75. Sapitri, A. I., Nurmaini, S., Rachmatullah, M. N., Tutuko, B., Darmawahyuni, A., Firdaus, F., ... & Islami, A. (2023). Deep learning-based real time detection for cardiac objects with fetal ultrasound video. *Informatics in Medicine Unlocked*, 36, 101150.
76. Mayo III, R. C., & Parikh, J. R. (2016). Breast imaging: the face of imaging 3.0. *Journal of the American College of Radiology*, 13(8), 1003-1007.
77. Daoud, M., & Mayo, M. (2019). A survey of neural network-based cancer prediction models from microarray data. *Artificial intelligence in medicine*, 97, 204-214.
78. Wang, G., Li, W., Ourselin, S., & Vercauteren, T. (2019). Automatic brain tumor segmentation using convolutional neural networks with test-time augmentation. In *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 4th International*.
79. Xie, H., Yang, D., Sun, N., Chen, Z., & Zhang, Y. (2019). Automated pulmonary nodule detection in CT images using deep convolutional neural networks. *Pattern Recognition*, 85, 109-119.
80. Bernal, J., Kushibar, K., Asfaw, D. S., Valverde, S., Oliver, A., Martí, R., & Lladó, X. (2019). Deep convolutional neural networks for brain image analysis on magnetic resonance imaging: a review. *Artificial intelligence in medicine*, 95, 64-81.
81. Hardalaç, F., Uysal, F., Peker, O., Çiçeklidağ, M., Tolunay, T., Tokgöz, N., ... & Mert, F. (2022). Fracture detection in wrist X-ray images using deep learning-based object detection models. *Sensors*, 22(3), 1285.
82. Ring, D., Jupiter, J. B., & Herndon, J. H. (2000). Acute fractures of the scaphoid. *JAAOS-Journal of the American Academy of Orthopaedic Surgeons*, 8(4), 225-231.
83. Waizenegger, M., Barton, N. J., Davis, T. R. C., & Wastie, M. L. (1994). Clinical signs in scaphoid fractures. *Journal of Hand Surgery*, 19(6), 743-747.
84. Dias, J. J., Brenkel, I. J., & Finlay, D. B. (1989). Patterns of union in fractures of the waist of the scaphoid. *The Journal of bone and joint surgery. British volume*, 71(2), 307-310.
85. Guan, B., Zhang, G., Yao, J., Wang, X., & Wang, M. (2020). Arm fracture detection in X-rays based on improved deep convolutional neural network. *Computers & Electrical Engineering*, 81, 106530.

86. Rajpurkar, P., Irvin, J., Bagul, A., Ding, D., Duan, T., Mehta, H., ... & Ng, A. Y. (2017). Mura: Large dataset for abnormality detection in musculoskeletal radiographs. arXiv preprint arXiv:1712.06957.
87. Guan, B., Yao, J., Zhang, G., & Wang, X. (2019). Thigh fracture detection using deep learning method based on new dilated convolutional feature pyramid network. *Pattern Recognition Letters*, 125, 521-526.
88. Hayashi, D., Kompel, A. J., Ventre, J., Ducarouge, A., Nguyen, T., Regnard, N. E., & Guermazi, A. (2022). Automated detection of acute appendicular skeletal fractures in pediatric patients using deep learning. *Skeletal Radiology*, 51(11), 2129-2139.
89. Wu, Y., Kirillov, A., Massa, F., Lo, W. Y., & Girshick, R. (2019). Detectron2.
90. Thian, Y. L., Li, Y., Jagmohan, P., Sia, D., Chan, V. E. Y., & Tan, R. T. (2019). Convolutional neural networks for automated fracture detection and localization on wrist radiographs. *Radiology: Artificial Intelligence*, 1(1), e180001.
91. Wu, H. Z., Yan, L. F., Liu, X. Q., Yu, Y. Z., Geng, Z. J., Wu, W. J., ... & Gao, B. L. (2021). The Feature Ambiguity Mitigate Operator model helps improve bone fracture detection on X-ray radiograph. *Scientific Reports*, 11(1), 1-10.
92. Xue, L., Yan, W., Luo, P., Zhang, X., Chaikovska, T., Liu, K., ... & Yang, K. (2021). Detection and localization of hand fractures based on GA_Faster R-CNN. *Alexandria Engineering Journal*, 60(5), 4555-4562.
93. Oka, K., Shiode, R., Yoshii, Y., Tanaka, H., Iwahashi, T., & Murase, T. (2021). Artificial intelligence to diagnosis distal radius fracture using biplane plain X-rays. *Journal of Orthopaedic Surgery and Research*, 16(1), 1-7.
94. Ma, Y., & Luo, Y. (2021). Bone fracture detection through the two-stage system of crack-sensitive convolutional neural network. *Informatics in Medicine Unlocked*, 22, 100452.
95. Lindsey, R., Daluiski, A., Chopra, S., Lachapelle, A., Mozer, M., Sicular, S., ... & Potter, H. (2018). Deep neural network improves fracture detection by clinicians. *Proceedings of the National Academy of Sciences*, 115(45), 11591-11596.
96. Hržić, F., Tschauner, S., Sorantin, E., & Štajduhar, I. (2022). Fracture Recognition in Paediatric Wrist Radiographs: An Object Detection Approach. *Mathematics*, 10(16), 2939.