



**MAKSİLLOFASİAL BÖLGEDE RADYOOPAK VE
RADYOLUSENT GÖRÜNTÜ VEREN LEZYONLARDA
YAPAY ZEKA MODELLERİNİN ETKİNLİĞİNİN
PANORAMİK RADYOGRAFİLER ÜZERİNDE
DEĞERLENDİRİLMESİ**

Zeynep TURANLI TOSUN
Ağız, Diş ve Çene Radyolojisi Anabilim Dalı

Tez Danışmanı
Prof. Dr. Muhammed Akif SÜMBÜLLÜ

Doktora Tezi-2024



SAĞLIK BİLİMLERİ ENSTİTÜSÜ
Graduate School of Health Sciences

**MAKSİLLOFASİYAL BÖLGEDE RADYOOPAK VE
RADYOLUSENT GÖRÜNTÜ VEREN LEZYONLARDA
YAPAY ZEKA MODELLERİNİN ETKİNLİĞİNİN
PANORAMİK RADYOGRAFİLER ÜZERİNDE
DEĞERLENDİRİLMESİ**

Zeynep TURANLI TOSUN

**Ağız Diş ve Çene Radyolojisi Ana Bilim Dalı
Doktora Tezi**

**Tez Danışmanı
Prof. Dr. Muhammed Akif SÜMBÜLLÜ**

**ERZURUM
2024**

İÇİNDEKİLER

İÇİNDEKİLER	I
TEŞEKKÜR	IV
ÖZET	V
ABSTRACT.....	VI
SİMGELER VE KISALTMALAR DİZİNİ	VII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ	XII
1. GİRİŞ	1
2. GENEL BİLGİLER.....	4
2.1. Maksillofasial Bölgede Radyoopak ve Radyolusent Görüntü Veren Lezyonlar	4
2.1.1. Maksillofasial Bölge Tanımı	4
2.1.2. Maksillofasial Bölgede Görülen Lezyonlar	4
2.1.3. Maksillofasial Bölgede Görülen Lezyonların Tanımlanması	11
2.1.3.1. Lezyonun Lokalizasyonu ve Orjini.....	11
2.1.3.2. Lezyonların Boyutu ve Sayısı	12
2.1.3.3. Lezyonun Sınırları ve Çevre Yapılara Etkisi	12
2.1.3.4. Lezyonun Dansitesi, İnternal Yapısı.....	13
2.2. Maksillofasial Bölgede Görülen Lezyonların Değerlendirilmesinde Kullanılan Diagnostik Radyolojik Teknikler	15
2.2.1. Konvansiyonel Yöntemler	17
2.2.1.1. Panoramik Radyografi	17
2.2.1.2. Periapikal Radyografi	21
2.2.1.3. Okluzal Radyografi.....	22
2.2.2. Bilgisayarlı Tomografi.....	22

2.2.3. Konik Işınlı Bilgisayarlı Tomografi	23
2.2.4. Manyetik Rezonans Görüntüleme (MRG).....	25
2.2.5. Ultrasonografi (USG)	26
2.2.6. Anjiyografi.....	27
2.2.7. Kemik Sintigrafisi (Radyonükleid Görüntüleme).....	28
2.2.8. Pozitron Emisyon Tomografi (PET).....	28
2.2.9. Sialografi.....	28
2.3. Yapay Zeka (Artificial Intelligence-AI)	29
2.3.1. Makine Öğrenmesi.....	31
2.3.2. Yapay Zeka Teknikleri	32
2.3.2.1. Uzman Sistemler (Expert Systems)	32
2.3.2.2. Bulanık Mantık	32
2.3.2.3. Genetik Algoritmalar	33
2.3.2.4. Yapay Sinir Ağları (Artificial Neural Network-ANN).....	33
2.3.3. Derin Öğrenme ve Evrişimli Sinir Ağları.....	35
2.3.3.1. Alex Net.....	37
2.3.3.2. VGGNet.....	38
2.3.3.3. GoogleNet.....	39
2.3.3.4. YOLO (You Only Look Once) ve YOLOv8.....	40
2.4. Diş Hekimliğinde Yapay Zekanın Kullanım Alanları	41
2.4.1. Ağız Diş ve Çene Radyolojisi Alanında Yapay Zeka Uygulamaları.....	44
3. MATERYAL VE METOT.....	48
3.1. Etik Kurul Onayı.....	48
3.2. Çalışmanın Dizaynı.....	48
3.3. Hastaların Seçimi	48

3.4. Klinik ve Radyolojik Verilerin Kaydedilmesi	50
3.5. Görüntülerin Etiketlenmesi	52
3.6. Veri Setlerinin Oluşturulması	54
3.6.1. Sınıflandırma-Classification	54
3.6.2. Nesne Tanıma-Object Detection.....	57
3.6.3. Segmentasyon-Görüntü Bölütleme	58
3.7. Algoritma Performanslarının Değerlendirilme Metrikleri.....	59
4. BULGULAR.....	63
4.1. Derin Öğrenme Mimarilerinin Performans Sonuçları	63
4.1.1. Maksillofasial Bölgede Radyopak ve Radyolusent Görüntü Veren Lezyonların Sınıflandırılmasında Derin Öğrenme Mimarilerinin Performans Sonuçları.....	63
4.1.2. Maksillofasial Bölgede Radyopak ve Radyolusent Görüntü Veren Lezyonların Tespitinde Derin Öğrenme Mimarilerinin Performans Sonuçları.....	84
4.1.3. Maksillofasial Bölgede Radyopak ve Radyolusent Görüntü Veren Lezyonların Segmentasyonunda Derin Öğrenme Mimarilerinin Performans Sonuçları	89
5. TARTIŞMA.....	103
6. SONUÇ VE ÖNERİLER.....	116
KAYNAKLAR	119
EKLER	140
Ek-1. Etik Bildirim ve İntihal Beyan Formu.....	140
Ek-2. Etik Kurul Onay Formu	141
Ek-3. Tez Adı Değişikliği Bildirim Formu.....	142

TEŞEKKÜR

Doktora tezi olarak sunduğum bu çalışmayı yöneten, eğitimim boyunca bana her konuda bilgisi ve tecrübesiyle yol göstererek bu zorlu süreci tamamlamamı sağlayan değerli tez danışmanım sayın Prof. Dr. M. Akif SÜMBÜLLÜ' ye,

Eğitimim süresince bilgi ve tecrübelerinden faydalandığım, tezimin her aşamasında ilgi ve desteklerini esirgemeyen, bütün zorlukları paylaştığım, saygıdeğer hocam Prof. Dr. Özkan MİLOĞLU'na,

Çalışmamızın yapay zeka uygulamalarıyla analizini yapan ve sonuçlarını elde eden sayın hocam Prof. Dr. İbrahim Yücel ÖZBEK ve ekibine,

Üniversite ve doktora eğitimim boyunca deneyimlerinden faydalandığım tüm Ağız, Diş ve Çene Radyolojisi Anabilim Dalı öğretim üyelerine, birlikte çalıştığım tüm asistan arkadaşlarıma, doktora öğrenimime fırsat tanıyan kurum amirlerime ve bu çalışmayı 11914 BAP proje numarası ile destekleyen Atatürk Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğüne,

Sonsuz emek, sevgi ve destekleri ile beni bu günlere getiren ve koşulsuzca sevildiğimi hissettiren canım aileme, yoğun eğitim dönemim boyunca sevgi ve sabırla beni destekleyen sevgili eşime ve doktora eğitimimin en başından beri en büyük fedakarlığı gösteren biricik oğluma sonsuz teşekkür ederim.

Zeynep TURANLI TOSUN

ÖZET

Maksillofasial Bölgede Radyoopak ve Radyolusent Görüntü Veren Lezyonlarda Yapay Zeka Modellerinin Etkinliğinin Panoramik Radyografiler Üzerinde Değerlendirilmesi

Amaç: Yapay zeka (YZ) temelde insan zekasını taklit eden ve veriler aracılığıyla nesneleri algılama, tanımlama, problem belirleme ve çözme gibi insan davranışlarını kopyalayan, insanlara özgü yetenekleri makinalar aracılığıyla yerine getiren sistemlerdir. Diş hekimliğinde yetersiz tecrübe, hatalı panoramik görüntüler, anatomik süperpozisyonlar ve yanlış tespit gibi nedenlerle gözden kaçırılacak lezyonların teşhisinde erken evrede yapay zekanın faydalı olabileceği düşünülmektedir. Geliştirilen YZ teknolojileri ile patolojik değişiklikler otomatik olarak saptanıp, sınıflandırılarak diş hekimlerine ve radyologlara dental radyografların incelenmesi ve yorumlanmasında ikinci bir görüş sağlanabilmektedir. Bu tez çalışmasının amacı, panoramik radyograflar üzerinde YZ tekniklerinden biri olan derin öğrenme yöntemi ile kullanılan algoritmaların maksillofasial bölgede radyoopak ve radyolusent görüntü veren lezyonların sınıflaması, tespiti ve segmentasyonundaki başarılarını değerlendirmektir.

Materyal ve Metot: Bu tez çalışmasına, radyolojik muayene sonucunda maksillofasial bölgede radyoopak veya radyolusent görüntü içeren 12-80 yaş aralığındaki bireylere ait panoramik görüntüler dahil edildi. Maksillofasial bölgede lezyonların varlığı ve yokluğu, dansitelerine bakılarak da radyoopak ya da radyolusent görüntü özelliğine göre, veri setleri oluşturuldu. Panoramik radyografilerden elde edilen veri seti üzerinde AlexNet, VGG16 ve GoogleNet mimarileri ile lezyonlar sınıflandırıldı. YOLOv8 mimarisi kullanılarak da lezyonların tespiti ve segmentasyonu yapıldı. Derin öğrenme mimarilerinin sınıflandırma performansları konfüzyon matrisi kullanılarak, nesne tespiti ve segmentasyon performansları ise precision recall eğrisi kullanılarak değerlendirildi.

Bulgular: Panoramik radyografinin bütünü üzerinde yapılan sınıflandırmada, derin öğrenme mimarilerine ait en iyi performanslara bakıldığında; iki sınıflı lezyon (var-yok) sınıflamasında en yüksek doğruluğu GoogleNet (%95.6), radyoopak-radyolusent lezyon sınıflamasında en yüksek doğruluğu VGG16 (%68.4), üç ve dört sınıflı lezyon sınıflandırmasında ise en yüksek doğrulukları GoogleNet (sırasıyla %61.1, %75.7) gösterdi. Panoramik radyografi üzerinden lezyonlu alanın kırılarak bakıldığı diğer bir sınıflandırmada ise en yüksek doğruluğu GoogleNet ve VGG16 modelleri aynı başarı oranı (%96.5) ile sergilediler. Nesne tespitindeki en yüksek doğruluk, YOLOv8 1 modelinde %75.4 başarı oranı ile elde edildi. Segmentasyon probleminde ise en yüksek başarıyı %72.1 oranı ile YOLOv 8 m sergiledi.

Sonuç: Bu tez çalışmasının sonucunda lezyonların tespiti, sınıflandırılması ve segmentasyonunda derin öğrenme mimarilerinin genel olarak yüksek doğruluk gösterdiği ancak veri setindeki görüntü sayısı ve çeşitliliği artırılarak yapılacak çalışmalarda daha başarılı sonuçlar alınabileceği kanısına varıldı. Derin öğrenmenin bu başarısı ile erken evrede lezyonların teşhisi yapılabileceği öngörülmekte, rutin kullanımda hekimlere yardımcı olacağı ve zaman kazandırabileceği düşünülmektedir.

Anahtar Kelimeler: Maksillofasial bölge, panoramik radyografi, radyolusent lezyon, radyoopak lezyon, yapay zeka

ABSTRACT

The Effectiveness of Artificial Intelligence Models on Radiopaque and Radiolucent Lesions in the Maxillofacial Region on Panoramic Radiography

Aim: Artificial intelligence (AI) is basically systems that imitate human intelligence and copy human behavior such as perceiving objects, identifying objects, identifying and solving problems through data, and performing human-specific abilities through machines. It is thought that artificial intelligence may be useful in the early stages in diagnosing lesions that may be overlooked due to reasons such as insufficient experience in dentistry, faulty panoramic images, anatomical superpositions and incorrect detection. With the developed AI technologies, pathological changes can be automatically detected and classified and a second opinion can be provided to dentists and radiologists in the examination and interpretation of dental radiographs. The aim of this thesis study is to evaluate the success of the algorithms used with the deep learning method, one of the AI techniques, on panoramic radiographs in the classification, detection and segmentation of radiopaque and radiolucent lesions in the maxillofacial region.

Material and method: In this thesis study, panoramic images belonging to individuals between the ages of 12-80, which contain radiopaque or radiolucent images in the maxillofacial region as a result of radiological examination, were included. Data sets were created based on the presence and absence of lesions in the maxillofacial region, their density, and radiopaque or radiolucent image characteristics. Lesions were classified using AlexNet, VGG16 and GoogLeNet architectures on the dataset obtained from panoramic radiographs. Detection and segmentation of lesions were also performed using YOLOv8 architecture. The classification performance of the deep learning architectures was evaluated using the confusion matrix, and the object detection and segmentation performances were evaluated using the precision recall curve.

Results: When looking at the best performances of deep learning architectures in the classification made on the whole panoramic radiography; GoogleNet has the highest accuracy in two-class lesion (present-absent) classification (95.6%), VGG16 has the highest accuracy in radiopaque-radiolucent lesion classification (68.4%), and GoogleNet has the highest accuracy in three- and four-class lesion classification (61.1%, 75.7%, respectively) showed. In another classification in which the lesioned area is viewed by cropping the panoramic radiography, GoogleNet and VGG16 models exhibited the highest accuracy with the same success rate (96.5%). The highest accuracy in object detection was achieved with a 75.4% success rate in the YOLOv8 l model. In the segmentation problem, YOLOv8 m showed the highest success with a rate of 72.1%.

Conclusion: As a result of this thesis study, it was concluded that deep learning architectures generally show high accuracy in the detection, classification and segmentation of lesions, but more successful results can be obtained in studies by increasing the number and diversity of images in the data set. With this success of deep learning, it is predicted that lesions can be diagnosed at an early stage, and it is thought that it will help physicians in routine use and save time.

Key Words: Artificial intelligence, Maxillofacial region, panoramic radiography, radiolucent lesion, radiopaque lesion

SİMGELER VE KISALTMALAR DİZİNİ

AI	: Artificial intelligence
ANN	: Artificial neural network
BBOX	: Bounding box
BT	: Bilgisayarlı tomografi
CBCT	: Konik ışınlı bilgisayarlı tomografi
CNN	: Convolutional neural network
DSÖ	: Dünya sağlık örgütü
ESA	: Evrişimsel sinir ağı
FN	: False negative
FP	: False positive
ILSVRC	: İmagenet large scale visual recognition challenge
kVp	: Kilovoltaj peak
mAP50	: Mean avarege precision
mAs	: Miliamper saniye
MRG	: Manyetik rezonans görüntüleme
ORAD	: Oral radiograph diagnosis
PET	: Pozitron emisyon tomografisi
PR	: Panoramik radyografi
RL	: Radyolusent
RO	: Radyoopak
SVM	: Support vectör machine (Destek vektör makinesi)
TME	: Temporomandibular eklem
TN	: True negative
TP	: True positive

USG	: Ultrasonografi
YOLO	: You only look once
YSA	: Yapay sinir ağıları
YZ	: Yapay zeka



ŞEKİLLER DİZİNİ

<u>Şekil No</u>	<u>Sayfa No</u>
Şekil 2.1. Diş ve periapikal patolojinin x-ışınlarını soğurma farklılıkları.....	14
Şekil 2.2. Panoramik radyografide anatomik landmarkların gösterimi.....	19
Şekil 2.3. Yapay zeka ile alt tekniklerinin ilişkisini temsil eden Venn diyagramı.....	31
Şekil 2.4. Makine öğrenimi(A) ve derin öğrenme modelleri(B)	36
Şekil 2.5. AlexNet mimarisi	38
Şekil 2.6. VGGNet’e ait model mimarisi	39
Şekil 2.7. GoogleNet’e ait model mimarisi	40
Şekil 3.1. Dijital panoramik radyogramda radyoopak ve radyolusent lezyon alanları izleniyor	51
Şekil 3.2. Panoramik radyogramda radyoopak görüntü veren lezyon izleniyor	52
Şekil 3.3. Panoramik radyogramda radyolusent görüntü veren lezyon izleniyor.....	52
Şekil 3.4. Panoramik radyogramda radyolusent görüntü veren lezyonun Makesense Al programı ile etiketlendiği izleniyor.....	53
Şekil 3.5. Panoramik radyogramda radyoopak görüntü veren lezyonun Makesense Al programı ile etiketlendiği izleniyor.....	53
Şekil 3.6. Evrişimsel sinir ağları ile lezyon sınıflandırmasının akışı izleniyor	55
Şekil 3.7. Radyoopak lezyonlara ait veri setleri izleniyor	55
Şekil 3.8. Radyolusent lezyonlara ait veri setleri izleniyor	56
Şekil 3.9. 10 kat çarpaz doğrulama yöntemi izleniyor	56
Şekil 3.10. Nesne tespitinde hazırlanan etiket dosyaları izleniyor	58
Şekil 3.11. Radyolusent lezyonun segmentasyonu izleniyor	59
Şekil 3.12. Konfüzyon matris tablosu	60
Şekil 3.13. Precision recall (kesinlik duyarlılık) grafiği.....	62

Şekil 4.1. Lezyon var-yok sınıflamasında AlexNet modeline ait konfüzyon matrisi.....	64
Şekil 4.2. Lezyon var-yok sınıflamasında VGG16 modeline ait konfüzyon matrisi	65
Şekil 4.3. Lezyon var-yok sınıflamasında GoogleNet modeline ait konfüzyon matrisi.	66
Şekil 4.4. Radyopak ve radyolusent lezyon sınıflamasında AlexNet modeline ait konfüzyon matrisi	68
Şekil 4.5. Radyopak ve radyolusent lezyon sınıflamasında VGG16 modeline ait konfüzyon matrisi	69
Şekil 4.6. Radyopak ve radyolusent lezyon sınıflamasında GoogleNet modeline ait konfüzyon matrisi	70
Şekil 4.7. Radyopak, radyolusent ve radyopak-radyolusent lezyon sınıflamasında AlexNet modeline ait konfüzyon matrisi	72
Şekil 4.8. Radyopak, radyolusent ve radyopak-radyolusent lezyon sınıflamasında VGG16 modeline ait konfüzyon matrisi.....	73
Şekil 4.9. Radyopak, radyolusent ve radyopak-radyolusent lezyon sınıflamasında GoogleNet modeline ait konfüzyon matrisi	74
Şekil 4.10. Radyopak, radyolusent, radyopak-radyolusent ve lezyon yok sınıflamasında AlexNet modeline ait konfüzyon matrisi.....	76
Şekil 4.11. Radyopak, radyolusent, radyopak-radyolusent ve lezyon yok sınıflamasında VGG16 modeline ait konfüzyon matrisi	77
Şekil 4.12. Radyopak, radyolusent, radyopak-radyolusent ve lezyon yok sınıflamasında GoogleNet modeline ait konfüzyon matrisi.....	78
Şekil 4.13. Kırpılmış panoramik radyografilerde radyopak ve radyolusent lezyon sınıflamasında AlexNet modeline ait konfüzyon matrisi.....	80
Şekil 4.14. Kırpılmış panoramik radyografilerde radyopak ve radyolusent lezyon sınıflamasında VGG16 modeline ait konfüzyon matrisi	81

Şekil 4.15. Kırpılmış panoramik radyografilerde radyoopak ve radyolusent lezyon sınıflamasında GoogleNet modeline ait konfüzyon matrisi.....	82
Şekil.4.16. PR’lerde kırpılmış lezyon alanları içerisinde lezyon çeşidine göre yapılan ikili sınıflandırmada, majority voting yaklaşımıyla elde edilen sonuçlara ait konfüzyon matrisi	83
Şekil 4.17. YOLOv8 s modeline ait precision-recall eğrisi.....	85
Şekil 4.18. YOLOv8 m modeline ait precision-recall eğrisi	86
Şekil 4.19. YOLOv8 l modeline ait precision-recall eğrisi	87
Şekil 4.20. YOLOv8 xl modeline ait precision-recall eğrisi	88
Şekil 4.21. YOLOv8 n bbox ve mask analiz sonuçları	91
Şekil 4.22. YOLOv8 s bbox ve mask analiz sonuçları	93
Şekil 4.23. YOLOv8 m bbox ve mask analiz sonuçları	95
Şekil 4.24. YOLOv8 l bbox ve mask analiz sonuçları	97
Şekil 4.25. YOLOv8 xl bbox ve mask analiz sonuçları	99
Şekil 4.26. Segmentasyon veri setine ait performans karşılaştırma grafiği.....	101
Şekil 4.27. PR’de radyolusent görüntü veren lezyonun segmentasyonu izleniyor	101
Şekil 4.28. PR’de radyoopak görüntü veren lezyonların segmentasyonu izleniyor	102
Şekil 4.29. PR’de hem radyoopak hem radyolusent görüntü veren lezyonların segmentasyonu izleniyor.....	102

TABLÖLAR DİZİNİ

<u>Tablo No</u>	<u>Sayfa No</u>
Tablo 2.1. Yapay sinir sistemindeki elemanların biyolojik sinir sistemindeki karşılıkları	34
Tablo 3.1. Nesne tanıma probleminde veri dağılımı	57
Tablo 4.1. Lezyon var yok sınıflamasında kullanılan yöntemlerin karşılaştırması	67
Tablo 4.2. Radyopak ve radyolusent lezyon sınıflamasında kullanılan yöntemlerin karşılaştırması	71
Tablo 4.3. Radyopak, radyolusent ve radyopak-radyolusent lezyon sınıflamasında kullanılan yöntemlerin karşılaştırması	75
Tablo 4.4. Radyopak, radyolusent, radyopak-radyolusent ve lezyon yok sınıflamasında kullanılan yöntemlerin karşılaştırması	79
Tablo 4.5. PR’lerde kırılmış lezyon alanları içerisinde, lezyon çeşidine göre yapılan ikili sınıflandırmada kullanılan yöntemlerin karşılaştırması	84
Tablo 4.6. YOLOv8 s nesne tespiti analiz sonuçları	85
Tablo 4.7. YOLOv8 m nesne tespiti analiz sonuçları	86
Tablo 4.8. YOLOv8 l nesne tespiti analiz sonuçları	87
Tablo 4.9. YOLOv8 xl nesne tespiti analiz sonuçları	88
Tablo 4.10. PR’lerde radyopak ve radyolusent lezyonların tespitinde kullanılan YOLOv8 modellerinin karşılaştırması	89
Tablo 4.11. YOLOv8 n segmentasyon analiz sonuçları	90
Tablo 4.12. YOLOv8 s segmentasyon analiz sonuçları	92
Tablo 4.13. YOLOv8 m segmentasyon analiz sonuçları	94
Tablo 4.14. YOLOv8 l segmentasyon analiz sonuçları	96
Tablo 4.15. YOLOv8 xl segmentasyon analiz sonuçları	98

Tablo 4.16. PR’lerde radyopak ve radyolusent lezyonların segmentasyonunda	
kullanılan YOLOv8 modellerinin karşılaştırması.....	100



1. GİRİŞ

Maksillofasial bölgede radyopak ve radyolusent görüntü veren lezyonlar çoğunlukla dental enfeksiyonlar, kistler, neoplaziler, çenelerdeki displazik değişimler ve metabolik hastalıklara bağlı olarak oluşabilir (Murat, 2019). Bu lezyonlar dental problemlere, fonasyon ve fonksiyon eksikliğine, estetik kayıplara neden olabileceği gibi bazen de hastada herhangi bir semptomu neden olmaksızın varlığını sürdürebilir. Kemik patolojileri, klinik muayeneyi takiben alınan radyografilerde tesadüfen rastlanabileceği gibi hastanın şikayetleri doğrultusunda alınan radyolojik yöntemlerle de tespit edilebilir.

Dental tedaviler öncesinde teşhis ve tedavi planlaması için yapılan radyolojik muayene, sıkça kullanılan önemli bir adımdır. Yapılan klinik ve radyografik muayene sonuçları hekimi teşhise götürür. Sıklıkla periapikal, oklüzal ve bitewing gibi intraoral teknikler ile panoramik radyografi gibi iki boyutlu görüntüleme imkânı sunan ekstraoral radyografik yöntemler kullanılır. İstenilen tetkik ve kullanılan yöntem, görüntülenecek alana göre özelleşir. Dental tedaviler öncesinde özellikle de cerrahi işlemlerde, maksillofasial bölgede görüntü veren radyopak ve radyolusent lezyonların varlığı ve lokalizasyonları dikkatli şekilde değerlendirilmelidir. Bu amaçla, genellikle başlangıç radyografisi olarak alınan panoramik radyografiler alt ve üst çeneyi aynı anda kapsadığı için geniş görüntüleme imkânı sunar. En büyük avantajı olarak sadece dişler değil çenelere ait diğer lezyonlar, temporomandibular eklem dejenerasyonları, maksiller sinüs hastalıkları ve tükrük bezi taşları gibi daha birçok patolojik oluşumların saptanmasına da olanak tanır (Ariji, Yanashita, ve ark., 2019). Maksillofasial bölgeye ait çok sayıda anatomik yapıyı bir arada ve tek bir görüntü üzerinde vermesi bakımından kullanışlıdır. Tekniğin uygulama kolaylığı, hastanın kooperasyonu açısından ergonomik olması ve çekim süresinin kısa olması gibi birçok avantajı da vardır (Flint ve ark., 1998; White & Pharoah, 2014).

Panoramik radyografi iki boyutlu görüntüleme yapar ve derinlik izlenemez. Anatomik yapıların birbiri üzerine olan süperpozisyonları, görüntülerde oluşan distorsiyon ve magnifikasyonlar, intraoral tekniklere göre çözünürlük ve detayın daha düşük olması bu yöntemin en önemli dezavantajlarıdır. İki boyutlu görüntüleme yeteneği ile kısıtlı bilgi verir ancak ileri görüntüleme teknikleri kadar maliyeti yüksek değildir ve hemen her klinikte de bulunabilir. Ayrıca, hastaların maruz kaldığı radyasyon miktarı ileri görüntüleme tekniklerine göre daha az ve uygulama süresi de daha kısadır.

Yapay zeka, insan zekasını taklit ederek makinalar aracılığıyla düşünce üretebilen sistemlerdir (Kunz ve ark., 2020). Yapay zeka ile ilgili radyoloji alanında çok sayıda çalışma mevcuttur. Bu teknolojinin yaygınlaşmasındaki amaçlar arasında tanı süresini, uzman kişilere olan ihtiyacı ve insan kaynaklı hataları azaltarak bazı durumlarda insan gözünün farkedemediğini yazılımlarla tespit etmek olabilir. Bu amaçla da radyolojik incelemelerde, henüz klinik belirtiler ortaya çıkmadan hastalıkların teşhis edilmesinde kullanılabilir. Radyolojik incelemelerde geliştirilen yapay zeka, diş hekimleri ve dentomaksillofasial radyologlar için değerlendirme ve yorumlamada yardımcı olabilir (Schwendicke ve ark., 2019).

Patolojik değişiklikleri kolaylıkla saptayarak ve sınıflandırarak değerli katkılarıyla diş hekimlerine ikinci bir görüş sağlayabilir (Kwon ve ark., 2020). Ayrıca implant planlamasında, ortodontik tanı ve tedavi aşamalarında, ortognatik cerrahide kullanılabilir (J.-H. Lee ve ark., 2020; Tuzoff ve ark., 2019) ve tedavi sonuçlarının değerlendirilmesine olanak sağlayabilir (Ilhan ve ark., 2020).

Çalışmamızda bu avantaj ve dezavantajları göz önüne alarak panoramik radyografi ile tespit edilen, maksillofasial bölgede radyopak ve radyolusent görüntü veren lezyonların varlığını ve lokalizasyonlarını yapay zeka yöntemi kullanarak tespit etmeyi amaçladık. Bu tez çalışması sonucunda elde edilecek başarı neticesinde, rutinde

kullanılan panoramik radyograflar üzerinden maksillofasial bölgede görüntü veren lezyonlar doğru, hızlı ve nesnel bir şekilde değerlendirilebilecek ve hekimlere tedavi öncesinde yararlı bilgiler sağlayabilecektir. Böylece ileri görüntüleme yöntemlerine duyulan ihtiyacın, hastalara verilen radyasyon miktarının, tanı süresinin ve görüntüleme işlemleri için harcanan maliyetlerin azaltılması da amaçlanmaktadır.



2. GENEL BİLGİLER

2.1. Maksillofasial Bölgede Radyopak ve Radyolusent Görüntü Veren Lezyonlar

2.1.1. Maksillofasial Bölge Tanımı

Maksillofasial bölge yüz ve çene bölgesini içeren anatomik alandır. Kafatasını oluşturan visserokranyum kemikler; lakrimal, nazal, palatinal kemikler, zigoma, vomer, konka nazalis inferior, maksilla ve mandibula ile nörokranyum yapılardan frontal ve etmoid kemikler maksillofasial bölgeyi oluşturan iskeletsel yapılardır (Çakmak, 2022). Günümüzde rutin dental muayene sırasında maksillofasial bölgedeki önemli anatomik oluşumların, anatomik varyasyonların, komplikasyonların ve bu bölgedeki lezyonların değerlendirilmesi radyolojik görüntüleme yöntemleri ile yapılabilmektedir.

2.1.2. Maksillofasial Bölgede Görülen Lezyonlar

Lezyon, genel olarak organizmanın herhangi bir dokusunda yaralanma, hastalık veya enflamasyon gibi sebeplerle meydana gelen patolojik veya anormal değişikliklerdir. Maksillofasial bölge farklı ve karmaşık anatomik yapılardan oluştuğu gibi bu bölgede meydana gelen lezyonlar da; dental enfeksiyonlar, odontojenik ve nonodontojenik kistler, tümörler, premalign ve malign lezyonlar, displazik değişimler, yumuşak doku kalsifikasyonları ve metabolik hastalıklar veya travma sonucu oluşan patolojiler gibi daha birçok farklı şekilde karşımıza çıkabilir (Haylaz ve ark., 2022). Bu lezyonlar çoğu zaman birbirlerine benzer özellikler göstermesine rağmen, köken aldıkları dokular, morfolojik ve histopatolojik özellikler, etiyoloji ve anatomik yerleşimlerine göre değişik isimlerle tanımlanmaktadır (Yalçın & Bozan). Lezyonların lokalize oldukları kemik ve kemik içerisinde yer aldıkları bölge, tanı konulmasında büyük öneme sahiptir. Çene kemiklerinden sadece birinde veya çenenin belirli bir bölgesinde lokalize olabileceği gibi maksillofasial bölgenin tamamına da yayılım gösterebilirler.

Maksillofasial bölgedeki lezyonların çoğu çenelerde lokalizedir. Çene kemikleri iskelet sistemindeki diğer tüm kemiklerden çeşitli yönlerden farklılık gösterir. Embriyolojik olarak sadece mezenşim kaynaklı değil, aynı zamanda ektomezenşimal hücrelerden de köken alan dişlerin oluşup geliştiği yapılardır (Slootweg, 2009). Dişlerin gelişim evresi olan odontogenezin çenelerde gerçekleşmesi nedeniyle epitel kaynaklı kist ve tümör gibi oluşumlara ve diş kaynaklı enflamatuvar lezyonlara bu bölgelerde sıklıkla rastlanmaktadır (White & Pharoah, 2014).

Maksillofasial bölgede en çok karşılaşılan lezyonlardan biri, diş kaynaklı enflamatuvar lezyonlardır. Diş çürükleriyle başlayan enflamasyonlar pulpal kavite aracılığıyla dişin apeksine ve çene kemiğine ilerler ve periapikal lezyon olarak adlandırılırlar. Vital olmayan dişlerin nekrotik pulpası, periapikal kemiği tahrip eden enflamasyona neden olabilir. Yine periapikal alanda pulpanın kronik enflamasyonuna tepki olarak oluşan ve radyopak görüntü veren, diffüz sınırlara sahip bir condensing osteitis görülebilir (Underhill ve ark., 1992). Periapikal lezyonların ayırt edici tanısı radyografik görünümüne göre yapılır. Granülomlar, sınırları belirgin radyolusent görüntü verirken kronik apikal abse ise sınırları belli olmayan diffüz bir görüntüye sahiptir. Lezyonların çaplarının bir santimden büyük ve çok belirgin sınırlı olması ise radiküler kistleri düşündürür (Natkin ve ark., 1984).

Kist; etrafı konnektif bağ doku ile çevrili, iç yüzeyi epitel ile döşeli ve içerisinde yarı sıvı veya sıvı materyal ihtiva eden patolojik bir kavitedir. Kist oluşumu, içeriğinde bulunan epitel dokusunun uyarılması ve aktivasyonu ile başlar. Vücutta epitel kalıntılarının en fazla maksillofasial bölgede bulunması sebebiyle çene kemiklerinde kistlere sıklıkla rastlanmaktadır. Çene kistleri, dental yapıların oluşumu ile ilişkili epitelden kaynaklı ise odontojenik kistler, farklı dokulara ait epitellerin inklüzyonları sonucu oluşuyorsa nonodontojenik kistler olarak iki grupta incelenebilir. Ayrıca klinik ve

radyolojik görüntü olarak gerçek kistlere benzeyen ama histopatolojik bulgularında epitel içermeyen yalancı kist olarak da adlandırılan pseudo kistlere de nadir de olsa çenelerde rastlanmaktadır (Regezi ve ark., 2003).

Çene kemiklerindeki kistlerin çoğunluğu dental dokulardan orjin alan odontojenik kistlerdir. Kistler sekonder olarak enfekte olmadıkları sürece asemptomatik olup uzun süre belirti vermeden büyüyebilirler. Boyutları küçük olduğunda çok farkedilmezler ama büyüdükçe lezyon merkezinde kemik yıkılımlarına yani rezorpsiyonlara, periferdeki kemikte ise kemik yapımına yani apozisyona neden olurlar ki buna ekspansif büyüme denilir. Daha büyük boyutlara ulaştıklarında kortikal kemiklerde perforasyona veya patolojik kırıklara da neden olabilirler. Mandibuladaki bu ekspansif büyüme, inferior alveolar kanalın yer değiştirmesine neden olabileceği gibi mental foramene de baskı yaparak parestezi oluşumuna neden olabilir. Maksillada ise nasal fossa tabanı ve maksillar sinüs duvarlarında perforasyon oluşturabilirler (Regezi ve ark., 2003).

Kistler; radyolojik görüntülerde sıklıkla düzenli radyoopak sınırla çevrili, radyolusent görüntüler olarak karşımıza çıkar. Büyümenin hızlı olduğu durumlarda opak sınır çok belirgin olmayabilir. Bazı durumlarda septalı, multiloküler görüntü verecekleri gibi kronikleşen durumlarda içerisinde kalsifik radyoopak odaklar barındıran lezyonlar şeklinde de görülebilirler.

2017 Dünya Sağlık Örgütü (DSÖ) sınıflandırmasında çene kistleri inflamatuvar kökenli odontojenik kistler ve odontojenik/odontojenik olmayan gelişimsel kistler olarak iki ana bölüme ayrılmıştır (El-Naggar ve ark., 2017). 2022 sınıflandırmasında ise herhangi bir alt bölümlenme olmaksızın 'çene kistleri' terimi kullanılmaktadır. Fakat kistlerin kökenlerini vurgulamak ve netlik kazandırmak amacıyla inflamatuvar odontojenik kistler, gelişimsel odontojenik kistler ve diğer çene kistleri olarak anlatılmıştır (Soluk-Tekkesin & Wright, 2022) .

Odontojenik Kistler

❖ Gelişimsel Orjinli

- ✓ Dentigeröz kist
- ✓ Odontojenik Keratokist
- ✓ Lateral periodontal ve botiroid odontojenik kist
- ✓ Gingival kist
- ✓ Glandüler odontojenik kist
- ✓ Kalsifiye odontojenik kist
- ✓ Ortokeratinize odontojenik kist

❖ Enflamatuvar Orjinli

- ✓ Radiküler kist
- ✓ Kollateral inflammatuar kist

Nonodontojenik Kistler

- ✓ Nazopalatin kanal kisti
- ✓ Median palatinal kist
- ✓ Median alveolar kist
- ✓ Globulomaksillar kist
- ✓ Nazolabial (nazoalveolar) kist

Yalancı Kistler

- ✓ Basit (travmatik, hemorajik) kemik kisti
- ✓ Anevrizmal kemik kisti

Tümör; hücrelerin kontrolsüz bir şekilde aşırı ve anormal proliferasyonu sonucu oluşturdukları doku kitlesidir. Tümörler köken aldıkları dokuya, davranış şekillerine, klinik ve histolojik özelliklerine göre benign ve malign olarak iki gruba ayrılırlar. Belirli

bir bölgede lokalize olan, başka bölgelere yayılım göstermeyen, lokal olarak cerrahi operasyonla alınabilen lezyonlar benign olarak düşünülebilir. Genellikle semptom vermeden büyüdüklerinden rutin dental muayene sırasında farkedilebilirler. Lezyona ait hücrelerin anormal bir şekilde proliferasyon olarak lenf ve kan yolları ile lenf bezlerine ve uzak dokulara metastaz yapması ve doku harabiyetine neden olması lezyonların malignitesinin bir göstergesidir. Kemikte meydana gelen tümörler veya tümör benzeri lezyonlar, kemik dokusundan, kartilaj dokulardan, kemik iliğinden, fibröz bağ dokudan, lenfoid dokulardan, nöral veya vasküler herhangi bir dokudan köken alabilmektedirler (Harorlı ve ark., 2014). Maksillofasiyal bölgede görülen tümörler köken aldıkları dokuya göre odontojenik ve non odontojenik olarak ikiye ayrılırlar. Dental dokuları içeren ve odontojenik epitelden kaynaklanan tümörler, odontojenik tümörler olup çenelerde mandibular kanalın üzerinde ve alveolar kemikte sıklıkla rastlanmaktadır. Nonodontojenik tümörler, vasküler veya nöral dokulardan kaynaklanarak mandibular kanalın içerisinde, kırıldak dokulardan kaynaklanarak mandibular kondiller bölge gibi kartilajöz hücrelerin yoğun olduğu yerlerde lokalize olabilirler (Bayrakdar, 2015).

Benign tümörler yavaş, malign tümörler ise hızlı büyüme potansiyeline sahiptir. Bu sebeple; radyografik görüntülerde benign tümörlerin sınırları düzgün, genellikle de oval veya yuvarlaktır. Ekspansif büyüme sergilerler ve komşu dental dokulara baskı uygulayıp iterler. Lezyon çevresinde reaktif kemik tabakaları oluşabilir. Malign tümörler hızlı büyür ve çevre dokulara invaze olurlar. Bu nedenle sınırları düzensizdir. Maksillofasial bölgeye ait tümörlerin veya tümör benzeri lezyonların radyolojik olarak internal yapısı; tamamıyla radyolusent veya tamamıyla radyopak olabileceği gibi radyolusent-radyopak görüntünün beraber izlendiği mikst bir görünüme de sahip olabilirler. Tümörlerde lezyonun internal yapısının özelliği, tanı konulmasında önemli ve yardımcı bir faktördür (Açıkgöz, 2015).

Çenelerde görülen tümörler 2022 yılında Dünya Sağlık Örgütü tarafından yapılan güncel sınıflandırma temel alınarak anlatılmıştır (Vered & Wright, 2022).

Odontojenik Tümörler

❖ Benign Epitelyal Odontojenik Tümörler

- Adenomatoid odontojenik tümör
- Skuamoz odontojenik tümör
- Kalsifiye epitelyal odontojenik tümör
- Ameloblastoma, unikistik
- Ameloblastoma, ekstraosseoz/periferal
- Ameloblastoma, conventional
- Adenoid ameloblastoma
- Metastaz yapan ameloblastoma

❖ Benign Mixed Epitelyal & Mezenşimal Odontojenik Tümörler

- Odontoma
- Primordial odontojenik tümör
- Ameloblastik fibroma
- Dentinojenik hayalet hücreli tümör

❖ Benign Mezenşimal Odontojenik Tümörler

- Odontojenik fibroma
- Sementoblastoma
- Semento-ossifying fibroma
- Odontojenik miksoma

❖ Malign Odontojenik Tümörler

- Skleroze odontojenik karsinom
- Ameloblastik karsinoma

- Clear cell odontojenik karsinoma
- Hayalet hücreli odontojenik karsinoma
- Primer intraosseoz karsinoma NOS
- Odontojenik karsinosarkoma
- Odontojenik sarkoma

Benign Maksillofasiyal Kemik ve Kıkırdak Tümörleri

- Osteom
- Osteokondrom
- Osteoblastom
- Kondroblastom
- Kondromiksoid fibrom
- Kemiğin desmoplastik fibroması

Malign Maksillofasiyal Kemik ve Kıkırdak Tümörleri

- Çene osteosarkomu
- Kondrosarkom ailesi
- Mezenşimal kondrosarkom
- Tfcp2 yeniden düzenlemesi olan rabdomiyosarkom

Maksillofasial bölgede çene kemiklerinin dışında maksillar sinüslerde de kist ve tümörlere rastlanmaktadır. En sık görülenleri kubbe şeklinde, homojen, radyopak görüntü veren retansiyon kistleridir. Osteoma, odontoma, fibroosteoma, karsinoma ve osteosarkom gibi tümörlere de rastlanmaktadır (Ozcan, 2017).

Kalsiyum tuzlarının kemik yerine yumuşak dokularda birikmesi sonucu oluşan kalsifikasyonlar da rutin muayenede radyografilerde görüntü verebilir. En yaygın olarak da panoramik radyogramlarda angulus mandibula çevresinde glossofaringeal hava

boşluğunda lokalize tek veya çok sayıda genellikle radyoopak görüntü veren kalsifiye lenf nodlarıdır (Harorlı ve ark., 2014).

Benign fibroosseöz lezyonlar da çenelerde yaygın olarak görülür (Dahlin & Unni, 1986). Hipersementoz, diş köklerinde sementin aşırı birikmesi sonucu köklerin davul tokmağı şeklinde görülmesine neden olur. Dişlerin periodontal ligaman aralığı ve lamina durası bozulmadan kalır. Periapikal semental displazi (sementoma), fibroosseöz bir hastalıktır ve bu periapikal lezyon mandibular anterior bölgede birden fazla dişte görülebilir. Radyolusent olarak başlayan lezyon, ikinci evrede radyolusent-radyoopak mikst görünüm, son evrede ise radyolusent sınırlı çevrili radyoopak görüntü sergiler.

Çenelerdeki yaygın opasitelere en sık olarak florid osseöz displazinin neden olduğu literatürde rapor edilmiştir (Wood & Goaz, 1991). Periapikal semental displaziye göre çevresindeki radyolusent sınır daha da incedir. Fibroosseöz lezyonlardan bir diğeri de daha sıklıkla maksilla posterior bölgede görülen fibröz displazidir. Lezyonlar buzlu cam olarak adlandırılan sınırları belirsiz yoğun radyoopasiteler şeklinde görülebilir (Goaz, 1987).

2.1.3. Maksillofasial Bölgede Görülen Lezyonların Tanımlanması

Maksillofasial bölgede meydana gelen herhangi bir lezyon değerlendirilirken bazı hususlar dikkate alınmalıdır.

2.1.3.1. Lezyonun Lokalizasyonu ve Orjini

Lezyonların bulundukları kemik ve kemikte yer aldıkları bölge tanı için önemlidir. Bazı lezyonlar çenelerin belirgin spesifik bölgelerini etkileyebileceği gibi bazı lezyonlar da çenelerde herhangi bir alanda hatta tüm maksillofasial bölgeyi etkileyebilecek şekilde görülebilir. Lezyonların maksillofasial bölge gibi genel dağılımlarının olduğu durumlarda endokrin veya metabolik hastalıklar düşünülebilir. Sarkom ve karsinomlar üst çenede daha sık görülürken metastatik tümörler alt çenede posterior bölgede daha sık görülür

(Adisa ve ark., 2011). Non odontojenik lezyonlar için spesifik bir alan bulunmazken, odontojenik lezyonlar çenelerde dental arklarda ortaya çıkar.

Lezyonun, inferior alveolar kanal ve sert damağa göre lokalizasyonu da orjini hakkında bilgi verebilir. Odontojenik lezyonlar genellikle mandibulada inferior alveolar kanalın üst kısmında, maksillada ise sert damağın alt kısmında alveol kemikte lokalize iken, kanalın altındaki lezyonların nonodontojenik olma ihtimali daha yüksektir. Kanal içerisinde seyreden lezyonlar ise vasküler veya nöral orjinli olabilir. Kıkırdak orjinli kondrom, kondroblastom, osteokondrom gibi lezyonlar kartilaj doku içeriği fazla olan kondil bölgesinde görülürken, kemik menşeyli osteoma, osteoblastoma, osteoid osteoma gibi lezyonlar maksillofasial bölgeyi oluşturan kemik yapılarda görülebilmektedir (Bayrakdar, 2015).

2.1.3.2. Lezyonların Boyutu ve Sayısı

Kemik lezyonları tek (fokal, soliter) veya multifokal olabilir. Çene kemiklerinde görülen lezyonlar çoğunlukla soliterdir. Lezyon boyutları tedavi planlamasında önemlidir ve boyutların belirlenmesinde ileri görüntüleme yöntemlerine ihtiyaç duyulmaktadır (Harorlı ve ark., 2014).


2.1.3.3. Lezyonun Sınırları ve Çevre Yapılara Etkisi

Lezyonun çevre yapılara etkisi, büyüme hızı ve davranış şekli hakkında bilgi verir. Lezyonun sınırlarının düzgün ve keskin marjine sahip olması yavaş büyüdüğünü gösterir. Yavaş büyüyen lezyonların etrafı, genellikle ince sklerotik hat ile çevrilmiş olarak izlenir. Sağlam kemik dokusu ile lezyon arasında, dar geçiş zonu denilen belirgin sınır bulunur. Yavaş büyüyen lezyonlar ayrıca dişlerde yer değişikliğine neden olabilir. Hızlı büyüyen lezyonlar genellikle agresiftir ve çevre kemiğe invaze olduklarından kemik doku ile lezyon arasında sınır bulundurmazlar. Yavaş büyüyen lezyonlarda kortikal

kemikte incelme olurken, hızlı büyüme potansiyeli sergileyen malign karakterli lezyonlar ise kemikte erozyona sebep olurlar (Harorlı ve ark., 2014).

2.1.3.4. Lezyonun Dansitesi, İnternal Yapısı

Lezyonlar çevre kemiklerin yoğunluğuna göre radyopak (RO), radyolusent (RL) ve karışık (mikst) olmak üzere 3 çeşit radyolojik görüntü verirler (Neyaz ve ark., 2008). Radyolojik görüntüleme sırasında x-ışınları yoğun bir cisim içerisinde geçerken cisim tarafından soğurulur ve reseptör yüzeyinde beyaz veya radyopak görüntü elde edilir. Çevresindeki yumuşak dokulara göre kemiğin yoğunluğu daha yüksek olduğundan, iyonize ışınları kemik daha fazla emer. Kemiğin X ışınlarını geçirmeme, soğurma yani radyopak olma özelliği, içeriğindeki kalsiyum tuzlarından kaynaklanır. X-ışınları, yıkıma sebep olmuş patolojilerden soğurulmadan geçer ve reseptörde karanlık veya radyolusent görüntü oluşturur (Şekil 2.1.) (Iannucci & Howerton, 2021). Radyografik görüntüde değişiklik meydana getiren olay, kalsifiye materyalin miktarındaki değişiktir. Bu değişikliğin radyografik olarak saptanabilmesi için kemik dokuda en az % 40-50'lik artış veya azalma olmalıdır (Davies & Pettersson, 2002). Çene lezyonlarının çoğunluğu radyolusenttir ve bu da ayırıcı tanıyı zorlaştırmaktadır (Dunfee ve ark., 2006).



Şekil 2.1. Diş ve periapikal patolojinin x-ışınlarını soğurma farklılıkları

Radyolusent Lezyonlar

Radyografi yöntemleri ile elde edilen görüntülerde izlenen radyolusent alanlar, karanlık veya siyah renk olarak görülen bölgeleri tanımlar. Radyolusent alanlar, yoğunlukları az olan veya hiç olmayan, x-ışınlarının geçmesine kolayca izin veren yapıları içermektedirler. Radyolusent görüntü kemikte yıkım olduğunu belirtir ve lezyonun içerdiği hava, gaz veya sıvı görüntüsünü yansıtır. Örneğin, dişlerde meydana gelen çürük lezyonları dişleri çevreleyen yapılara kıyasla daha az yoğun olup, x ışının geçişine kolaylıkla izin verirler. Bu nedenle diş çürükleri radyolusent görüntü verirler. Radyolusent görüntü veren diğer yapılara dişin pulpası, periodontal ligament aralığı, yumuşak dokular ve hava boşlukları örnek verilebilir. Dişlerin periapikal bölgelerindeki meydana gelen radyolusensiler daha sıklıkla periapikal abse, granülom veya periapikal kistleri düşündürülebilir. Ameloblastoma, santral dev hücreli granülom, odontojenik

miksoma, adenomatoid odotojenik tümör, dentigeröz kist, odontojenik keratokist, insisiv kanal kisti gibi lezyonlar da radyolusent görüntü verirler (Yılmaz, 2018).

Radyopak Lezyonlar

Radyografi yöntemleri ile elde edilen görüntülerde izlenen radyopak alanlar beyaz veya parlak renk olarak görülen bölgeleri tanımlar. Radyopak görüntü veren yapılar, x-ışınlarının geçişine izin vermeyen ve x ışınlarını soğurabilen yüksek yoğunluğa sahip yapılardır. Radyopak görüntü veren lezyonlar içeriğindeki yüksek kalsifiye materyal miktarına bağlı olarak yoğun dansiteye sahip olup, radyopak görüntü oluştururlar. Osteoma, maksillofasial bölgede görülen radyopak lezyona verilecek en güzel örnektir. Odontoma, osteokondroma, sementoblastoma da radyopak görüntü veren lezyonlardandır. Distrofik kalsifikasyonlar da radyopak görüntü verir ve genellikle panoramik radyografilerde yoğun karnabahar şeklinde izlenen kalsifiye lenf nodulleri örnek verilebilir. Diş yapısını oluşturan mine ve dentin, diş çevreleyen kemik doku ve uygulanan metalik restorasyonlar da radyopak görüntü verirler (Yılmaz, 2018).

Bazı lezyonlar da radyopak ve radyolusent karışık (mikst) görüntü verirler. Kemik veya kıkırdak içerikli matriks üreten tümörlerde radyolusent litik alanlar içerisinde radyopak alanlar görülebilir. Osteoid tipteki matriksde bulunan dens yapılar solid veya sisli görüntü verirken, kartilajinöz tipte noktasal veya patlamış mısır görüntüsü veren dens yapılar izlenebilmektedir (Açıkgöz, 2015).

2.2. Maksillofasial Bölgede Görülen Lezyonların Değerlendirilmesinde Kullanılan Diagnostik Radyolojik Teknikler

Maksillofasial bölgede meydana gelen lezyonların birçoğu benzer radyografik görünüme sahiptir ve lezyonları birbirinden ayırt etmek çoğu zaman zordur. Anamnez ve klinik muayenenin devamında kemik lezyonunun olabileceği düşünülen hastalarda radyolojik inceleme ilk ve en önemli araştırma yöntemi olmaya devam etmektedir (Neyaz

ve ark., 2008). Klinik muayeneye ilave olarak radyografik incelemelerin yapılması, lezyonların tanısını güçlendirmektedir. Hatta bazen sadece radyografilerden bile lezyonlara tesadüfi olarak rastlamak mümkündür. Primer kemik tümörleri gibi bazı lezyonlar klinik belirti vermediği için bu lezyonların erken tanısında radyolojik incelemeler hekimleri doğrudan tanıya götürebilir. Bununla birlikte, radyografik görüntülerin yorumlanmasının bireysel tecrübe ve yetenek ile ilişkili olması, radyografik muayenenin önemli sınırlamalarından birisidir (Azimi ve ark., 2016). Maksillofasial bölge lezyonlarının görüntülenmesi için kullanılan yöntemler, lezyonların boyutları, lokalize oldukları alan, davranışları ve marjinlerine göre değişiklik gösterebilir (Bayrakdar, 2015). Radyografik muayeneye karar verildikten sonra yapılacak ilk iş, lezyonun görüntüleneceği en iyi radyografi tekniğini seçmektir. Diş hekimliğinde intraoral ve ekstraoral yöntemler olmak üzere geleneksel olarak iki büyük radyografi tekniği vardır ve bu teknikler 2 boyutludur. İntraoral yöntemler; bitewing, oklüzal ve periapikal radyografi olmak üzere 3 çeşittir (White & Pharoah, 2014). İntraoral radyografiler, küçük, düzgün sınırlı bir lezyonu karakterize etmede dişler ve kemikler için son derece ayrıntılı bir görünüm sunar. Ancak film boyutları küçük olduğu için genellikle 3 cm'den büyük lezyonlarda kullanılmazlar. Daha büyük lezyonları incelemek ve maksillofasial bölgeye ait yapıları görüntülemek için ekstraoral radyografiler kullanılır. Ekstraoral radyografi tekniklerinde, x-ışını kaynağı ve imaj reseptörü oral kavitenin dışında yer alır. Bu yöntemle yapılan görüntülemelere, panoramik, sefalometrik, submentoverteks, Reverse Towne, Waters teknikleri örnek verilebilir (Harorlı ve ark., 2014). Diş hekimliğinde kullanılan bu 2 boyutlu radyografi tekniklerinin avantajlarının yanında dezavantajları da bulunmaktadır. Geleneksel radyografiler üç boyutlu yapıların iki boyutlu görüntülerini elde ettikleri için sınırlı bir değere sahiptirler (Avril ve ark., 2014). Oluşan süperpozisyonlar, incelenmesi zor olan baş-boyun bölgesinin

değerlendirilmesini daha da zorlaştırmaktadır. Bu durum da 2 boyutlu radyografi tekniklerini yetersiz kılmaktadır. Bu gibi durumlarda bu tekniklerin yanında 3 boyutlu radyografik teknikler de kullanılmaktadır (Ozcan, 2017). Maksillofasial bölgede kortikal kemikte ekspansiyona sebep olacak kadar büyük boyutlara ulaşmış lezyonların ebatlarının belirlenmesinde veya çevre dokularla ilişkisinin incelenmesinde bilgisayarlı tomografi (BT), konik ışınlı bilgisayarlı tomografi (CBCT), ultrasonografi (USG), manyetik rezonans görüntüleme (MRG) ve sintigrafi gibi ileri görüntüleme yöntemlerinden yararlanılabilmektedir (Vandenberghe ve ark., 2010). Konik ışınlı bilgisayarlı tomografi (CBCT) ile maksillofasial bölgedeki patolojik oluşumların lokalizasyonu, boyutları, şekilleri ve radyodansiteleri incelenebileceği gibi yine bu bölgede meydana gelen kalsifikasyonların da ayırıcı tanısı yapılabilmektedir (Harorlı ve ark., 2014).

2.2.1. Konvansiyonel Yöntemler

Maksillofasial bölge lezyonlarının radyolojik olarak incelenmesinde düşük radyasyon dozu, zaman tasarrufu ve uygulama kolaylıkları gibi nedenlerle rutinde periapikal, okluzal, panoramik ve konvansiyonel lateral grafipler tercih edilmektedir. Düz grafipler çevre anatomik yapıların süperpozisyonu nedeniyle lezyonların kesin tanısında yetersiz olsa da lezyonların büyüklükleri, lokalizasyonları ve köken aldıkları doku hakkında fikir vererek, ayırıcı tanıda düşünülen ihtimallerin daraltılmasına olanak sağlar (Açıkgöz, 2015).


2.2.1.1. Panoramik Radyografi

Diş hekimliğinde alt ve üst çenelerdeki dişlerin, çenelerdeki patolojik oluşumların ve komşu anatomik yapılarla ilişkilerinin incelenmesi için başlangıç tetkik grafisi olarak çoğunlukla panoramik radyografiler (PR) tercih edilmektedir (Farman, 2007). Alt ve üst çenenin birlikte görüntülenmesi noktasında ilk çalışmalar 20. yüzyılda ABD’li bilim

adamı A.F. Zulauf tarafından 1922 yılında yapılmıştır. Dar bir ışın demetiyle çenelerin görüntülenmesini sağlayan özel bir yöntem geliştirmiş ve ürettiği cihaza ‘Panoramik X Işın Cihazı’ adını vererek ilk cihazın patentini almıştır (Drage & Rout, 2010). 1957 yılında Paatero 3 rotasyon merkezli bir ortopantomograf geliştirmiş ve Helsinki Üniveristesi Diş Tedavi Kliniği’nde kullanılmaya başlanmıştır (Paatero, 1961).

Panoramik radyografinin görüntüleme prensibinde, X ışını kaynağı ve bir görüntü reseptörü yani film kaseti hastanın başının etrafında eşit hızda ve ters yönde döner. Bu esnada tüpten çıkan X ışınları, film kaseti ile obje arasında bulunan kolimatörden objeyi geçerek filme ulaşır ve tüm rotasyon boyunca kesitler halinde objenin görüntüsünü oluşturur. Fokal Trough yani imaj tabakası denilen bölgede yer alan objeler net görüntü verirken bu alanın dışındaki objeler bulanık görünür (Aşçı, 2014).

Panoramik görüntü, düz bir düzlem üzerine açılmış kavisli çeneyi temsil eder. Panoramik görüntü posterior bölgelerde çenelerin sagittal (lateral) görünümünü gösterirken, anterior bölgede koronal (anteroposterior) görünümü temsil eder (Şekil 2.2) (White & Pharoah, 2014).



Şekil 2.2. Panoramik radyografide anatomik landmarkların gösterimi

Panoramik radyografiler alt ve üst çenelerdeki dişleri, orbitanın 1/3 üne kadar maksillar bölgeyi, bilateral maksillar sinüsleri ve temporomandibular ekleme (TME) ait anatomik yapıları tek bir görüntü üzerinde gösterebilmektedir. Maksillofasial bölgeye ait kemikler ile maksilla ve mandibuladaki dental arkları kapsayan geniş bir görüntüleme alanına sahip olması, kısa sürede görüntüyü elde etmesi, tekniğin kolay uygulanabilirliği, radyasyon dozunun düşük olması, mental retarde veya trismus gibi nedenlerle ağız açıklığı kısıtlı olup intraoral radyografiyi tolere edemeyen hastalarda kullanılabilir olması panoramik radyografinin avantajlarıdır. Buna karşın, küçük detayları net bir şekilde görüntülemeye intraoral radyografiler kadar yeterli değildir. Süperpozisyonlar nedeniyle özellikle premolar dişlerde interproksimal alanlardaki çürük lezyonlarının gözden kaçırılmasına neden olabilirler. Servikal vertebralar ve hava yolu arkları gibi anatomik

oluşumların neden olduğu süperpozisyonlar, hayalet imajların varlığı ile hatalı yorumlamalara neden olabilirler. Geometrik distorsiyonlar ve eşit olmayan magnifikasyonların oluşması gibi diğer dezavantajlara da sahiptir (White & Pharoah, 2014).

Diş hekimliğinde çocuklarda süt, karışık ve daimi dentisyonlarda dişlerin gelişimleri ve sürmelerinin takip edilmesi, erişkin hastalarda diş anomalileri ve gömük dişlerin değerlendirilmesi, protez ve implant tedavilerinin planlanması ve cerrahi sonrası kontrollerinin sağlanması, travmaya bağlı fraktür hatlarının tespit edilmesi, temporomandibular eklem rahatsızlıklarının belirlenmesi, çenelerde ve görüntüleme alanına giren maksillofasial bölgelerdeki lezyonların tanısı amacıyla kullanılmaktadır (Ozcan, 2017).

Maksillofasial bölgedeki lezyonların başlangıç radyografik tetkileri için en uygun yöntem panoramik radyografilerdir. Lezyonların şekli, lokalizasyonu, sınırları ve internal yapısı hakkında ön bilgi edinilmiş olunur. Panoramik radyografi, karışık görüntü veren bir lezyonun radyolusent ve radyopak komponentlerini içeren internal yapısını net bir şekilde gösterip, lezyonun şekli ve sınırları hakkında bilgi verebilir (Bayrakdar, 2015).

Bazı panoramik röntgen cihazları ile; lateral oblik, lateral kafa, postero-anterior, waters, caldwell, bregmamentum, oksipitontental, submentoverteks ve sefalometrik gibi çeşitli ekstraoral projeksiyonların çekimi yapılabilmektedir. İhtiyaç duyulduğu durumlarda lezyonun konumuna göre bu projeksiyonlar da çene lezyonlarının değerlendirilmesi için kullanılabilir (Bayrakdar, 2015). Panoramik radyografinin doğru bir şekilde yorumlanması, tanıya ulaşmak için ihtiyaç halinde kullanılacak ileri görüntüleme yöntemlerine karar vermede önemlidir (Lim ve ark., 2018).

2.2.1.2. Periapikal Radyografi

İntraoral radyografilere kıyasla panoramik radyografilerin daha az detaya (Kim ve ark., 2008) ve bazı dezavantajlara sahip olması (Mol, 2004) intraoral radyografilerin özellikle de periapikal radyografilerin kullanımını öncelikli hale getirmiştir.

Periapikal radyografilerde dişlerin, dişleri çevreleyen destek yapıların, interdental kemik yapılarının ve periapikal bölgede meydana gelen lezyonların infero süperior ve meziodistal yöndeki görüntüleri iki boyutlu olarak incelenir. Dişlerin periapikal bölgesindeki değişimlerin tespiti, alveol kemikte yerleşim gösteren kist ve lezyonların değerlendirilmesi, lezyonların büyüklükleri, etkilenen diş veya diş kökleri ile ilişkisi, bir kökteki lezyonun diğer kökle bağlantısının değerlendirilmesinde kullanılabilir.

Dişlerde vital ya da nekrotik pulpa kaynaklı bir enflamasyon sonucu, akut veya kronik seyreden süreçte periapikal bölgede kemik yıkımları ile periapikal lezyonlar oluşabilir. Kemik yıkım alanında x-ışınlarının absorpsiyonu daha az olduğu için periapikal radyogramlarda bu bölgeler radyolusent olarak izlenir (White & Pharoah, 2014). Anterior bölgelerdeki lezyonların netliği açısından özellikle panoramik radyografilere göre daha performanslı olması periapikal radyografilerin önemli avantajlarından (Molander ve ark., 1993).

Periapikal radyografilerde, kemik yıkılımının veya osseoz artışın ilerlediği küçük boyutlu lezyonlar rahatlıkla teşhis edilebilmektedir. Fakat lezyonların kortikal kemikte veya ilişkili olduğu anatomik yapılarda ekspansiyon veya perforasyona neden olup olmadığını periapikal radyografilerle değerlendirmek mümkün olmamaktadır. Bu tür durumlarda iki boyutlu radyografilerin limitasyonlarını ortadan kaldıran ileri görüntüleme yöntemlerine ihtiyaç duyulmaktadır (Lofthag-Hansen ve ark., 2007).

2.2.1.3. Okluzal Radyografi

Muayene sırasında ihtiyaç duyulduğunda, periapikal radyografilere ilave olarak okluzal radyografiler de kullanılabilir. Okluzal radyografiler ile lezyonların bukko lingual veya bukko palatinal yöndeki genişlikleri, sublingual ve submandibular tükrük bezlerinin kanallarındaki taşların lokalizasyonları değerlendirilebilir.

2.2.2. Bilgisayarlı Tomografi

1963 yılında Cormak tarafından üzerinde çalışılmaya başlanmış ve 1972 de Godfrey Hounsfield tarafından geliştirilmiş ileri görüntüleme yöntemlerinden biri olan bilgisayarlı tomografi (BT) yönteminde, vücudun incelenmesi istenen belirli bir kesitinden ince bir hat şeklinde geçen X ışınlarının dokular tarafından emilimindeki farklılıklar detektörlerle ölçülerek bilgisayara kaydedilir. Böylece istenilen derinlikteki lezyonların ve anatomik yapıların görüntülenmesi sağlanır. BT nin lezyonların absorpsiyon değerlerini belirleyerek dokudaki dansite farklılıklarını ayırt edebilmesi sayesinde gözle farkedilmeyecek patolojik oluşumlar kolaylıkla belirlenir ve lezyonların içerikleri hakkında fikir edinilebilir. Fakat solid bir kitlenin malign veya benign ayrımını yapamaz. Kesitsel görüntüleme yapıldığı için görüntülenmesi istenen her yapı süperpozisyonlu, farklı düzlemlerde ve diğer tabakalar bulanıklaşmadan üç boyutlu olarak incelenebilir (Gümüş, 2021).

BT; Kemik dokuyu çok iyi görüntüler ve kemik içi lezyonların farklı düzlemlerde 3 boyutlu incelenerek lokalizasyonun, boyutunun, çevre dokularla ilişkisinin belirlenmesine olanak sağlar. Bu nedenle maksillofasial bölgede oluşan malign ve benign tümörler, çeşitli enfeksiyonlar, kistler, kalsifikasyonlar gibi kemikte meydana gelebilecek patolojik oluşumların incelenmesinde kullanılan değerli bir teşhis yöntemidir (Bayrakdar, 2015).

BT; diş hekimliğinde, maksillofasial bölgede yer alan ve diğer radyografi yöntemleri ile tespit edilmiş ya da şüphelenilmiş lezyonların tespit edilmesi ve sınırlarının belirlenmesinde, lezyon kaynaklı kortikal ekspansiyon ve destrüksiyonların belirlenmesinde, cerrahi işlem öncesi tedavi planlamasında, tükürük bezine ait patolojik oluşumların tespit edilmesinde, maksillofasial bölgedeki travmaların, konjenital deformitelerin değerlendirilmesinde, paranazal sinüslerdeki enflamatuvar değişiklikler ve anatomik varyasyonlarının belirlenmesinde, implant operasyonu öncesi kemiğin yüksekliği ve kantitesinin değerlendirilmesinde, TME'nin anatomik yapısı ve patolojilerinin incelenmesinde kullanılabilir (Harorlı ve ark., 2014). Alternatif olarak kullanılan diğer yöntemlere göre yüksek radyasyon dozuna sahip olması, metalik dental restorasyonların oluşturduğu artefaktlar nedeniyle incelenecek anatomik yapının belirsizleşmesi, geniş yer kaplaması ve pahalı olması tekniğin dezavantajlarından (Harorlı ve ark., 2006). Bu nedenle, maksillofasial bölgeye ait anatomik yapıların ve lezyonların incelenmesinde daha az dezavantajlar sunan Konik Işınlı Bilgisayarlı Tomografi (CBCT) daha çok tercih edilmektedir (Scarfe & Farman, 2008).

2.2.3. Konik Işınlı Bilgisayarlı Tomografi

İlk nesil CBCT 1982'de anjiyografi işlemleri kullanılmış ve daha sonraları Mozzo ve ark., (1998) tarafından diş hekimliği alanına özel CBCT tekniği tanıtılmıştır. Günümüzde maksillofasial kemik yapısı daha iyi görüntüleyebilmesi, BT ile kıyaslandığında radyasyon dozunun altıda bir oranda daha düşük olması ve düşük dozla, 3 boyutlu, yüksek çözünürlüğe sahip görüntüleri kısa sürede elde edilebilmesi, iki boyutlu radyografilerdeki geometrik distorsiyon, magnifikasyon ve süperpozisyon gibi dezavantajları ortadan kaldırması nedeniyle diş hekimliği radyolojisinde rutinde daha çok kullanılmaya başlanmıştır (Pauwels ve ark., 2012; Orhan, 2012).

CBCT cihazlarında iki boyutlu dedektör ve hastaya yelpaze şeklinde ulaşan ışın yerine konik şekilli X ışını kullanılarak, hastanın başının çevresinde tek rotasyonel hareketi ile maksillofasial bölgenin görüntüsü elde edilebilmektedir. Elde edilen dijital görüntüler üzerinden aksiyal, koronal ve sagittal olarak multiplanar görüntüler oluşturulabilir (Scarfe & Farman, 2008). Dijital görüntülerin en küçük birimleri voksellerdir ve voksellerin boyutları ile çözünürlük değerlendirilir. Voksellerin boyutu küçüldükçe görüntünün çözünürlüğü artar. BT’de voksel boyutları büyük ve dikdörtgenler prizması (anizotropik) şeklindeyken CBCT’de voksel boyutları küçük ve kübiktir (izotropik) (Harorlı ve ark., 2014). Bu iki özellik neticesinde CBCT’lerde görüntü çözünürlüğü BT’lere kıyasla daha fazladır. Bu nedenle CBCT ile alınan görüntülerde maksillofasial bölge ve dentoalveolar yapılar daha detaylı incelenebilmektedir.

CBCT görüntüleme tekniği ile gömük dişler, paranasal sinüsler, tme, periodantal kemik defektleri, periapikal lezyonlar ve patolojik oluşumlar, dental ve kraniyofasial anomaliler, kistler ve tümörler değerlendirilebilmekte ortodontik tedavi ve ortognatik cerrahi, preoperatif implant planlaması kolaylıkla yapılabilmektedir (Orhan ve ark., 2016; Ozcan, 2017).

Düşük radyasyon dozu kullanan CBCT’lerde Hounsfield ölçümünün yapılamaması ve yumuşak doku kontrast çözünürlüğünün çok düşük olması gibi sebeplerle dansiteye bağlı ölçümlerde kullanımı sınırlıdır. Yine de çenelerde tespit edilen lezyonların kist veya tümör olma olasılığı hakkında bilgi sağlayabilirler (Guo ve ark., 2013). Simon ve ark. (2006) tarafından yapılan çalışmada 17 hastaya ait periapikal lezyonun 13 üne kist 4 üne de granülom ön tanısı CBCT taramaları sonucu konulmuş ve lezyonların cerrahi operasyonu sonrası biyopsi sonuçlarının CBCT ile konulan ön tanı ile

aynı olduđu belirlenmiřtir. CBCT ile non invaziv olarak teřhis koyma ve takip etme imkanının olduđu belirtilmiřtir.

CBCT’de sert dokular yksek znrlkte ve ince kesitler halinde detaylı olarak incelenebildiđi iin maksillofasial blgede oluřan lezyonların boyutları, sınırları evre anatomik yapılarla iliřkisi, dental yapılara olan etkisi farklı dzlemlerde grntlenerek teřhis ve tedaviye karar verilebilmektedir.

İki boyutlu radyografilere gre maliyetinin yksek olması, panoramik cihazlarla kıyaslandığında iyonize radyasyon dozunun daha fazla olması, verilerin yorumlanmasında deneyim gerektirmesi, medikal BT’ler gibi Hounsfield lmnn yapılamaması, metalik yapılardan kaynaklanan artefaktların oluřması, yumuřak dokuların grntlenmesinde MRG ile kıyaslandığında sınırlı kapasiteye sahip olması gibi dezavantajları da bulunmaktadır (Seth ve ark., 2011).

2.2.4. Manyetik Rezonans Grntleme (MRG)

MRG; vcuttaki hidrojen atomlarının manyetik bir alan ierisinde radyofrekans dalgaları ile uyarılması sonucu hidrojen atomlarında oluřan hareketliliđin grntye dnřtrlmesi iřlemidir. BT gibi kesitsel grntleme yapılabilirdiđi iin detaylı inceleme imkânı sunar. Elde edilen grntlerle 3 boyutlu rekonstrksiyon yapılabilirdiđi iin multiplanar grntleme sađlar.

MRG’de X ışını kullanılmadıđı iin grntlerde artefakt bulunmadıđı gibi hamilelerde ve ocuklarda kullanılabilir. Aynı hastada tekrarlayan ekimler yapılabilir. Diř hekimliđinde zellikle TME tetkiklerinde eklem diskini, kasları, bađ dokuyu ayrı ayrı grntleyebildiđi iin genellikle tercih edilir.

Yumuřak doku kontrast rezolusyonu en yksek olan bu teknik, temel olarak yumuřak dokuların veya kemik dokudan yumuřak dokuya invaze olan lezyonların incelenmesi iin kullanılmaktadır. Kemikle ilgili incelemelerde yetersiz kalsa da kemik

iliğine ait intramedullar lezyonlarda kortikal harabiyet olmadan önce bilgi verir (Hasbek ve ark., 2013). Kontrast madde kullanılmadan vasküler yapılar ve kan akımı görüntülenebilir. Lezyonunun iç yapısını belirlemede, kistik veya tümoral yapıda olup olmadığını, tümörlerdeki vasküler değişiklikleri görüntülemeye kullanılabilecek en iyi yöntemdir. Tümörün, peritümöral ödem ve nekrozdan ayırt edilmesinde, benign ve malign tümörlerin ayrımında, rezidüel tümörün belirlenmesinde, tümörün vasküler değişiklikleri ile kemoterapiye yanıtının değerlendirilmesinde de kullanılabilir (Theodorou ve ark., 2003; Van der Woude ve ark., 1995). Ancak kemiğin kortikal yüzeylerindeki erozyon miktarını ve minimal kalsifikasyonları belirlemede yetersizdir. Bu sebeple kemik ve yumuşak doku tutulumunu birlikte sergileyen tümörlerin değerlendirilmesinde BT ve MRG yöntemlerinin korelasyonu gerekmektedir (Açıkgöz, 2015).

2.2.5. Ultrasonografi (USG)

Ultrasonografi, yüksek frekanslı ses dalgalarının incelenmesi istenen anatomik veya patolojik yapılara probalar aracılığıyla gönderilmesi ve bu yapılardan dalgaların yansımaları sonucu eş zamanlı görüntü elde edilebilen radyolojik yöntemdir.

Maksillofasial bölgedeki şişlikler, enfeksiyonlar, kistler, tümörler ve periapikal lezyon gibi kemik içi lezyonların değerlendirilmesinde, tükürük bezlerinin yapıları ve beze ait patolojik oluşumların görüntülenmesinde kullanılır.

Ultrasonik dalgaların kemik üzerinden tamamen yansımaları, oral kavite ve paranasal sinüs gibi boşlukların arkasında kaybolması nedeniyle ultrason daha çok yumuşak doku incelemesinde kullanılır (Schön ve ark., 2002).

Maksillofasial bölgedeki kemik lezyonlarının tanısı için ultrasonografinin kullanımı ile ilgili az sayıda çalışma mevcuttur. İlk olarak intraosseöz lezyonların tanısında ve lezyon içeriklerinin değerlendirilmesinde tamamlayıcı görüntüleme yöntemi olarak kullanılmıştır (Dib ve ark., 1996). Daha sonra yapılan çalışmaların periapikal

lezyonların içeriklerine göre farklılıkları sunması, kist ve granülom ayrımlarının USG ile başarılı bir şekilde yapılabildiğini göstermiştir (Cotti ve ark., 2002; Gundappa ve ark., 2006). Bukkal kortikal kemiğin ince veya perfore olduğu alanlarda USG ile incelemenin lezyon içeriği hakkında bilgi verebileceğine yönelik çalışmalar da mevcuttur (Shahidi ve ark., 2015). Odontojenik tümör içeriklerinin homojen ve yoğun olması nedeniyle USG’de hiperekojen görüntü verirken, odontojenik kistler sıvı içeriklerinden dolayı anekoik görüntü verirler (Evirgen & Kamburoğlu, 2016). Sümer ve ark. (2009) yaptıkları çalışmada, USG’de kemikiçi lezyonların içeriği ile ilgili bilgi elde edilebileceği ve lezyonların vaskülarizasyonunun doppler ultrason ile gösterilebileceğini bildirdiler.

2.2.6. Anjiyografi

Anjiyografi; kateter aracılığıyla damar yoluna verilen kontrast maddeler ile vasküler anevrizmaların, darlıkların, arteriyovenöz malformasyonların, lezyonlardaki anormal damarlanmaların görüntülenmesidir. Maksillofasial bölgede görülen intraosseöz vasküler lezyonlar oldukça azdır ve tüm intraosseöz lezyonların %1’inden daha azını oluşturup, diğer çene lezyonları ile karıştırılabilir. Maksillofasial vasküler lezyonların tanımlanmasında lezyonun içeriği, sınırı ve morfolojisi, besleyici damarlar, kan akışının durumu ve çevre dokulardaki tutulum miktarı önemlidir. Bu amaçla bilgisayarlı tomografi, manyetik rezonans ve kateter anjiyografi yöntemlerinden yararlanılabilmektedir (Handa ve ark., 2014).

Yapılan bir çalışmada, maksillofasial bölgedeki sekiz adet arteriyovenöz malformasyonun tamamı BT ve kontrastlı BT’de değerlendirilmiş ve kontrastlı BT’de lezyon sınırlarının bilgisayarlı tomografiye göre daha net olduğu belirtilmiştir (Tao ve ark., 2010).

2.2.7. Kemik Sintigrafisi (Radyonükleid Görüntüleme)

Damar yolu veya solunumla radyoaktif maddenin vücuda verilerek incelenmesi istenen doku ve organdaki dağılımını görüntüleyen bir yöntemdir. Klasik radyografilerde lezyonların morfolojik ve anatomik farklılıkları değerlendirilirken radyonükleid görüntülemeye, doku ve organlarda semptomlar gelişmeden önceki biyokimyasal değişiklikler görüntülenir. Kemik metastazlarında, çok sayıda kemik tutulumu olan lezyonlarda, metastatik ve malign tümörlerin tanısında tercih edilen ilk yöntemdir. Aynı anda tüm iskelet sistemi kolay ve hızlı şekilde değerlendirilebilir (Hasbek ve ark., 2013). Ayrıca sialografinin kontrendike olduğu durumlarda tükrük bezlerinin değerlendirilmesi için de kullanılır (Harorlı ve ark., 2014).

2.2.8. Pozitron Emisyon Tomografi (PET)

Pozitron yayan radyoaktif ajanların hastaya enjekte edilerek dokuların metabolizmasını inceleyen ve nükleer tıpta kullanılan bir görüntüleme tekniğidir. Radyoaktif hale getirilmiş glukoz kanser hücreleri gibi enerjiye ihtiyaç duyan hücreler tarafından tutulur. Tümörlerin glukoz afinitesinin fazla olması malignite belirtisidir (Sakamoto ve ark., 1997). Bu nedenle, malign kitle lokalizasyonunda, metastazların tanısında, baş boyun bölgesindeki tümörlerde PET tarama sensitivitesi daha fazla olduğu için oldukça kullanışlıdır (Di Martino ve ark., 2000).

2.2.9. Sialografi

Majör tükrük bezlerinin duktal morfolojisini, tükrük bezi kanallarındaki opak ve nonopak taşları, tümoral oluşumları, bez içerisindeki patolojik oluşumları kontrast madde aracılığıyla inceleyen görüntüleme yöntemidir (Başaran, 2024). Duktal sistemin ince, hassas anatomisini inceleyen ve tıkanıklıkları en doğru şekilde görselleştiren tek muayene yöntemidir.

Sialografi, daha çok parotis ve submandibular bezlerin görüntülenmesinde ve en sık da tükürük taşlarının belirlenmesinde kullanılır. Bez içerisinde lokalize olan tükürük taşları kalsifikasyon miktarına bağlı olarak radyolusent veya radyoopak kitleler şeklinde görülebilirler (Isacsson ve ark., 1984). Ancak sialografi ile iyi bir görüntü elde edebilmesi uygulanan görüntüleme tekniklerinin sınırlamaları nedeniyle kısıtlıdır. Örneğin tükürük taşları konvansiyonel grafilerle tespit edilebilirler. Fakat bu radyografik tekniklere bağlı olarak oluşan magnifikasyon ve distorsiyonlar, komşu anatomik yapıların süperpozisyonları taşın lokalizasyonunu ve büyüklüğünü belirlemeyi, görüntünün kalitesini ve netliğini etkileyebilir (Çağlayan, 2016). Son zamanlarda sialografi için görüntüleme aracı olarak bez parankiminin daha iyi görüntülenmesine ve sialolitlerin tanımlanmasına olanak sağlayan CBCT' den yararlanılmaktadır (Jadu & Lam, 2013). Bununla birlikte özellikle küçük ve bez dışındaki kitlelerin görüntülenmesinde sialografi kullanımı sınırlıdır.

2.3. Yapay Zeka (Artificial Intelligence-AI)


Yapay zeka (YZ) temelde insan davranışlarını kopyalayan, zekasını taklit eden ve veriler aracılığıyla nesneleri algılama, tanımlama, problem belirleme ve çözme gibi insanlara özgü yetenekleri makinalar aracılığıyla yerine getiren sistemlerdir (Mertoğlu ve ark., 2023).

Yapay zeka, verilen eğitimler kadar bilgi birikimine ve bakış açısına sahiptir. Çevre koşullarından etkilenmediği için verdiği yanıtlar öğretildiği şekilde tutarlıdır. Yaratıcılık, esinlenme, sürekli öğrenme gibi doğal zekaya özgü özellikleri taşımaz. Bununla birlikte verilen bilgilerin makinalar aracılığıyla depolanması doğal zekadaki gibi unutulma riskini ortadan kaldırır. Yapay zeka ile bilgiler depolanıp gerektiğinde belgelenebilirken doğal zeka da bu zordur. Fakat daha önce öğretilmeyen yeni durumlarla karşılaştığında insan zekası gibi deneyimleri kullanma ve muhakeme yeteneğiyle cevap

veremez. Eğitim sürecinden geçtikten sonra verilen yanıtlar daha hızlıdır (Pirim, 2006; Shabbir & Anwer, 2018).

Bu alandaki ilk çalışma 1943 te McCulloch ve Pitts tarafından yapılan insan beynindeki nöronları matematiksel olarak modelleyerek beyine ait devre modelinin oluşturulmasıdır (Pirim, 2006). 1947 yılında akıllı makinalar ile ilgili ilk konferansı veren Alan Turing, yapay zekanın çok iyi makinalarla değil, bilgisayar programlarıyla araştırılabileceğini belirtmiştir. 1950 yılında yazdığı makalede, makinaların da insanlar kadar akıllı ve zeki olabileceğini, makine etkileşiminde insan karşısındakinin yapay zeka mı veya insan mı olduğunu ayırt edemiyorsa, yapay zekanın da insan zeka seviyesine ulaşabildiğini savunmuş ve Turing testini tanımlamıştır (Turing, 2009). Yapay zeka problemlerinin mantıksal ve mimari temelini oluşturan bu test, günümüzde de yapay zeka programlarında kullanılmaktadır. 1956 yılında Mccarthy, Dartmouth Kolejindeki konferansta yapay zeka terimini ilk kullanan kişi olmakla birlikte bu konferans da yapay zekanın tartışıldığı ilk bilimsel ve resmi toplantı olmuştur (Moor, 2006). Daha sonraları uzman tabanlı ve bilgi tabanlı sistemlerin geliştirilmesi ve yapay sinir ağlarına dönüştürülmesi ile endüstride, askeri sistemlerde ve robotik oyunlarda kullanılarak günümüze kadar ulaşmış, çok sayıda bilimdalı ile de multidisipliner çalışma imkanı bulmuştur (Yılmaz, 2021). Tıp ve diş hekimliği alanlarında hastalıkların tanısının konulması, tedavilerin planlanması ve hasta randevularının düzenlenmesi gibi yardımcı uygulamalarda yapay zeka kullanımı yaygınlaşmaktadır (Jiang ve ark., 2017). Farklı uygulama alanlarına özgü gereksinimlere yanıt verebilmek için yapay zekanın geliştirilmiş birden çok yöntemi bulunmaktadır.

Yapay zeka; makine öğrenimi, derin öğrenme ve yapay sinir ağları olarak alt başlıklarda incelenebilmektedir (Şekil 2.3) (Khanagar ve ark., 2021).



Şekil 2.3. Yapay zeka ile alt tekniklerinin ilişkisini temsil eden Venn diyagramı

2.3.1. Makine Öğrenmesi

Yapay zekayı oluşturan önemli alt başlıklardan biri olan makine öğrenimi; insan fiili olmadan algoritmaları, doğrudan veri grubundan öğrenip, duruma özgü cevap oluşturarak problemlerin çözülmesi için geliştirilmiştir. Makine öğrenimi, çok sayıda verinin yüklenmesi ile görüntüleri öğrenir. Problemleri tespit ederek, alt sınıflara ayırabilir böylelikle gelişip, tecrübe kazanabilir. Problemler karşısında tahminlerle çözüm üretebilmektedir (Sen ve ark., 2020). İnsan tarafından verilerin etiketlenerek makine öğrenimi eğitilmiş ise sonuçlar kişinin verileri değerlendirdiği şekle göre değişiklik gösterir. Yani eğitilmiş kişiler tarafından yüksek doğrulukla yapılanları bilgisayarlar yaklaşık olarak tahmin edebilmektedir. Fakat sınıflandırma veya etiketleme yapılmadan doğrudan verilerle öğrenen makine öğreniminde insan kaynaklı hatalar bulunmaz. Bu şekilde de makine öğrenimi, modelleri kavramaya çalışır ve tahmin yapmaz. Veri sayısının artışıyla değerlendirmenin doğruluğu aynı oranda artar (Deo, 2015).

2.3.2. Yapay Zeka Teknikleri

2.3.2.1. Uzman Sistemler (Expert Systems)

Belirli bir alanda uzmanlaşmış kişilerin problemlere karşı çözümsel yaklaşımlarını örnek alan düzenli bilgi kaynağına sahip bilgisayar sistemleridir. Yapay zekadan farklı olarak insanların çözeceği problemleri değil uzmanların çözdüğü problemleri hedefler. Amaç uzmanların yerini almak değil uzmanlara ulaşım imkânı olmayan yerlerde problem çözümlerine yardımcı olmaktır. Başlıca kullanım alanları arasında tıp ve biyomedikal branşları yer almaktadır (Serhatlıoğlu & Hardalaç, 2009). 1970 yılında bakteriyel menenjitin tanı ve tedavisi için Stanford Üniversitesinde ilk uzman sistem olan MYCIN tasarlanmıştır (Pirim, 2006).

2.3.2.2. Bulanık Mantık

Kesinlik olmayan, ara değerlerde yaklaşık olarak düşünme ile işlem yapan matematiksel sistemlerdir (Zadeh, 1965). Klasik veri gruplarında var-yok, uzun-kısa, 0-1, siyah-beyaz gibi kesin olan iki değer vardır. Fakat bulanık veri kümesinde kesinlik olmayıp orta ve ara değerlerde yaklaşık muhakemeyele işlem yapılır. Zadeh ilkelerine göre mantıksal ifadelerin hepsi bulanık olan ifadeye dönüştürülebilir. Matematiksel olarak zor ve karmaşık olan sistemler için en uygun yöntem bulanık mantık yöntemidir. Metro işleyişleri, trafik lambalarının düzeni, çamaşır makinası ve elektrikli süpürge gibi ev aletlerinin programlanması, buzdolaplarındaki buzlanmanın önlenmesi, el yazısı, nesne ve karakter tanıma gibi gündelik hayatta çeşitli alanlarda kullanılmaktadır (Keskenler & Keskenler, 2017).

Bulanık mantığın kullanıldığı bir sistemle, dişlere yapılan bleaching işlemi sonrası dişin doğal rengi üzerinden işlem sonrası dönüşeceği renk tonu öngörülmüştür (Herrera ve ark., 2010).

2.3.2.3. Genetik Algoritmalar

Genetik algoritmalar problemlerin çözümünde evrimsel süreçten esinlenerek kalıtsal özellikleri temel alan matematiksel hesaplama modelleridir (Mathew, 2012). Olasılıksal bir metod olan genetik algoritmanın temeli, doğal seçim yani güçlü olanın kazanması prensibine dayanır. Genetik algoritmalar karmaşık olan problemlere birbirinden bağımsız birden fazla çözüm üretebilir. Bu çözümler sonrasında eşleştirilerek yüksek performanslı çözümler oluşturulur (Öztürk & Şahin, 2018).

2.3.2.4. Yapay Sinir Ağları (Artificial Neural Network-ANN)

İnsan beynindeki nöronların her biri gelen bilgiyi alır, işler ve cevap olarak iletir. Yapay sinir ağları (YSA) yapay nöronlar kullanarak insan beynindeki sinir ağını ve insana ait becerileri taklit eden matematiksel bilgisayar programlarıdır (Abraham, 2005).

Yapay sinir ağlarının eğitim süreci insan zekasına benzer. Ne kadar çok örnek verilerek eğitilirse problemin çözümü o kadar kolay olacaktır. Çünkü yapay sinir ağları örneklerle bilgileri toplar, gruplandırır, olaylar arasında ilişki kurup, çıkarım yapar ve daha önce hiç karşılaşmadığı durumlarda insan zekası gibi tecrübe ve hatırlama yeteneklerini kullanarak karşılaştığı durum ile ilgili karar verebilir. Bu özellikleri nedeniyle karmaşık problemleri çözmede üstün performans gösterir (Ergezer ve ark., 2003).

Yapay sinir ağlarının fonksiyonel elamanları olan yapay nöronların hepsi birbirleriyle ilişkili olup nöronlar arasındaki bağlantının ve nörona ait her bir elemanın biyolojik sinir ağlarındaki kavramsal olarak karşılığı mevcuttur (Nichols ve ark., 2019). Yapay sinir sistemindeki elemanlar ile bunların biyolojik sinir sistemindeki karşılıkları ise Tablo 2.1’de gösterilmektedir (Öztürk & Şahin, 2018).

Tablo 2.1. Yapay sinir sistemindeki elemanların biyolojik sinir sistemindeki karşılıkları

Yapay sinir sitemi	Biyolojik sinir sistemi
İşlemci elemanı	Nöron
Toplama fonksiyonu	Dentrit
Transfer fonksiyonu	Hücre Gövdesi
Yapay nöron çıkışı	Akson
Ağırlıklar	Sinaps

Yapay sinir ağlarında giriş ve çıkış katmanı ile bu ikisinin arasında ara katman veya diğer ismiyle gizli katman bulunur. Giriş katmanı dışardan gelen bilgileri entegre eder ve bu katmanda bilgiler işlenmez. Giriş katmanından iletilen bilgiler ara katmanlarda işlenir ve ara katman çoğunlukla bir tane olup kullanıcı isteğine bağlı olarak belirlenmektedir. Çıktı katmanından ise sonuçlar alınmaktadır. Tek katmanlı YSA modellerinde ara katman bulunmaz (Bishop, 1995). Eğitim sürecinde hedeflenen çıktılar ile yapay sinir ağı sisteminden elde edilen çıktılar arasındaki hataların veya farkların, ağ içerisindeki katmanların ağırlıklarıyla dengeli olarak dağıtılarak minimize edilmesi amaçlanmaktadır (Rumelhart ve ark., 1986).


Yapay sinir ağlarının hızlı olması, kompleks problemleri basitçe çözümleyebilmesi, insana özgü öğrenme, optimize etme çıkarımda bulunma gibi özelliklerinin bulunması, işlem elemanlarından birinde oluşan hasarın sistemin işlevini aksatmaması ve başarıda düşüşe sebep olmaması gibi avantajlarından dolayı günümüzde kullanım alanları giderek artmaktadır. Özellikle sağlık alanında yapılan çalışmalarda kalp yetmezliği, anjina pectoris ve miyokard enfarktüsü tanı ve klinik uygulamalarında başarılı sonuçlar elde edilmiştir (Baxt, 1991). Bunun dışında otomotiv sektöründe plaka tanımlamada, ulaşımda trafik akışının kontrolünde (Tektaş ve ark., 2002) el yazısı, parmak izi ve ses tanımda, meteorolojik tahminlerde, endüstriyel, elektronik, havacılık ve uzay bilimleri gibi pekçok alanda yapay sinir ağlarından yararlanılmaktadır. Yapay sinir

ağlarından robotik uygulamaların geliştirilmesi şu anki en güncel yaklaşımlardır. İnsan gibi yürüyüp koşabilen ASIMO robotu bu teknolojinin son örneğidir (Öztürk & Şahin, 2018).

2.3.3. Derin Öğrenme ve Evrişimli Sinir Ağları

Yapay zekanın en güncel sürümü olan derin öğrenme, makine öğreniminin alt grubu olup ilk olarak Rina Dechter tarafından 1986 yılında tanıtılmıştır. 2012 yılında nesne tanıma yarışmasında derin öğrenmenin mimarisi olan evrişimsel sinir ağı modelinin kazanılmasıyla bilim dünyasında büyük ilgiye sebep olmuştur (Krizhevsky ve ark., 2012). Makine öğreniminden daha kompleks yapıya sahip olup, temeli insan zekasından esinlenerek oluşturulan yapay sinir ağlarına dayanmaktadır (Jacob, 2019). Fakat yapay sinir ağlarındaki katman sayısı açısından farklılık göstermektedir. Derin öğrenme yönteminde yapay sinir ağlarından daha fazla sayıda gizli katman mevcuttur. Bu katmanlar aracılığıyla girdilerden veriler alınmaktadır. Çok katmanlı olması sayesinde daha zor ve karmaşık problemleri çözebilecek yetenektedir (Lee ve ark., 2017).

Derin Öğrenme; ön işleme aşaması olmadan etikenlenmemiş, işlenmemiş ve sınıflandırılmamış ham verinin özelliklerini tanımlayarak tahminde bulunur (Şekil 2.4) (Suzuki, 2017). Verilerin boyutu, karmaşıklığı, kontrastları, lezyonların özellikleri ve organ tespitleri kolaylıkla yapılabilmektedir. Büyük boyutlu verilerin işlenmesi, insan seslerini ayırt etme, lezyonları tespit etme, gen analizi, nesneleri piksellerle eşleştirme gibi karmaşık ve kompleks problemlerin çözümü yapay zeka teknikleri ile zordur. Derin öğrenme yöntemi verileri hiyerarşik düzen içinde sınıflandırarak bu kompleks problemlere makine öğrenimi ve yapay sinir ağlarından daha kolay çözüm sunmaktadır (LeCun ve ark., 2015). Bu nedenle yapay zeka ile görüntü yorumlama işlemi yapan sistemlerin çoğunun temelini derin öğrenme oluşturmaktadır (Lee ve ark., 2017).



Şekil 2.4. Makine öğrenimi(A) ve derin öğrenme modelleri(B)

Derin öğrenmede veri sayısının fazlalığı başarıyı aynı oranda etkilemektedir. Yine ara katmanların sayısının artması ile daha büyük hafızaya sahip hızlı çalışan bilgisayarlara ihtiyaç duyulmaktadır. Son zamanlarda büyük modelleri çalıştırabilecek yeteneğe sahip ve donanımsal ihtiyaçları karşılayacak güçlü bilgisayarların kullanımı ve dijitalleşen toplumda fazlaca verinin bilgisayar ortamında kayıt altına alınabilmesi sayesinde derin öğrenme büyük ilerleme kaydetmiş, tıp ve diş hekimliği gibi sağlık hizmetleri veren, elektronik verilerin fazla olduğu alanlarda uygulanabilirliği artmıştır (Chen & Lin, 2014; Zhang ve ark., 2018).

Evrişimsel Sinir Ağı (ESA) Convolutional neural network (CNN); derin öğrenmenin en sık kullanılan ve temel mimari modeli olan evrişimsel sinir ağları yapay sinir ağlarının gelişmiş halidir. Yapay sinir ağlarında bulunan gizli katmanların sayısı artırılarak evrişimsel sinir ağı denilen derinleşen ağlar oluşturulmaktadır. Derinleşen bu ağ yapının her katmanında nesnelerin ayrı ayrı özelliklerinin keşfedildiği hiyerarşik öğrenme düzeni mevcuttur. Evrişimsel sinir ağları ile kullanılan veriler resim, video veya ses olabilmektedir. ESA’da görüntüyü oluşturan pikseller kenar motiflerini, motifler

nesne parçalarını ve en sonda nesne parçaları birleşip nesneyi oluşturmaktadır (LeCun ve ark., 2015). Evrişimsel sinir ağları öncelikli olarak görüntüleri sınıflandırmada etkin iken, nesneleri tanımlama ve segmentasyon problemlerinde de büyük başarı sergilemektedir (Özkan & Ülker, 2017).


Fakat problemlerin çözümünde ESA'nın kullanılmasında sıklıkla karşılaşılan sorunlardan biri, probleme göre eğitilmiş veri setinin yetersizliğidir. ESA'nın çoklu katman içerdiğinden probleme özgü nitelikleri doğru şekilde ortaya çıkarabilmesi için yeterli miktarda bilgi içeren eğitim setinin oluşturulması gerekir. Örneğin, ImageNet veri seti milyonlarca etiketlenmiş görüntüden oluşturulmuştur. Bu şekildeki eğitim kümesi ile eğitilmiş ESA modeli sınıflandırma problemlerinde oldukça yüksek performans göstermektedir. Bununla birlikte probleme özgü yeterli sayıda etiketlenmiş veri bulmak zordur. Veri sayısının az olduğu bu gibi durumlarda, eğitim konusunda başarısı ispatlanmış ImageNet gibi büyük veri kümesiyle eğitilen CNN modellerinden bilgi transferi yapılabilmektedir. Derin öğrenme tekniklerinin geliştirilmesi ile birlikte “transfer öğrenme” olarak bilinen bu yöntem önemli bir araştırma konusu haline gelmiştir (Fırıldak & Talu, 2019). Transfer öğrenme; veri setinin sınırlı, hesaplama gücünün yetersiz ve sürenin kısıtlı olduğu durumlarda, öncesinde büyük veri grubuyla ve uzun sürede eğitilmiş modellerin bilgileri kullanılarak, çözümlenecek problem üzerine parametrelerin aktarılması işlemidir. Böylelikle az sayıda etiketlenmiş veri olsa bile yüksek başarı elde edilebilmektedir (Koçer, 2012).

Derin öğrenme yönteminde kullanılan evrişimsel sinir ağı modellerine AlexNet, VGGNet, GoogleNet ve YOLOv 8 mimarileri örnek olarak verilebilir.

2.3.3.1. Alex Net

1000 adet objeyi sınıflandırabilecek şekilde tasarlanan bu model 2012 yılında Krizhevsky ve ark. (2012) tarafından geliştirilen ve aynı yıl yapılan ILSVRC (İmageNet

Large Scale Visual Recognition Challenge) yarışmasını kazanarak derin öğrenme alanında büyük ilgi uyandıran, derin sinir ağı mimarisidir. 25 katmanlı bu sinir ağında verilerin özniteliklerinin belirginleştirildiği 5 adet konvolüsyon katmanı, işlenen verilerin miktarını azaltan 3 adet havuzlama katmanı, 3 adet full connected katman, 7 adet verilerin aktivasyon fonksiyonunun olduğu relu katmanı, ezberlemeyi kaldırıp ağın performansını artıran 2 adet dropout katmanı, 2 adet ölçeklendirme katmanı, sınıflandırma yaparken olasılıksal değerleri üreten entropi (softmax) katmanı, girdi ve sınıflandırma (çıkıtı) katmanları bulunmaktadır. Girdi katmanındaki görüntünün boyutu 227x227x3 olup, sınıflandırma yapılan son katmanda ise girişteki görüntünün sınıflandırmadaki sayısal değeri verilir. Bu model kullanılarak yapılan nesne tanımlama işleminde doğruluk payı %80'lere kadar ulaşmıştır. Şekil 2.5.'de AlexNet'e ait mimari model gösterilmektedir (Doğan & Türkoğlu, 2018).




Şekil 2.5. AlexNet mimarisi

2.3.3.2. VGGNet

VGGNet mimarisinin içerdikleri katman sayısına göre toplamda 41 katmanlı VGG16 ve toplamda 47 katmanlı VGG19 olan iki farklı varyantı mevcuttur. Diğer modellerden farklı olarak daha derin ağ yapıları içermektedirler. Girdi katmanındaki görüntünün boyutu 224x224x3 olup sınıflandırma katmanı son katmandır. Matrislerin

giriş katmanından sınıflandırma katmanına doğru genişlik ve yükseklikleri azalırken derinlikleri artmaktadır. Bu model kullanılarak yapılan sınıflandırmalar %88-%89 oranında doğruluğa ulaşabilmiştir (Simonyan & Zisserman, 2014). Şekil 2.6.’da VGGNet’e ait model mimarisi gösterilmektedir (Mascarenhas & Agarwal, 2021).



Şekil 2.6. VGGNet’e ait model mimarisi

2.3.3.3. GoogleNet

İncepion modülleri nedeniyle karmaşık bir yapıya sahip olan GoogleNet mimarisi diğer mimarilerden farklı olarak ardışık yapıdaki konvolüsyon ve ‘max pooling’ yani havuzlama katmanlarını üst üste yığmak yerine paralel bağlanan modüller şeklinde kullanmıştır. Böylelikle ağın derinliği artırılarak sistemin eğitim aşamasında aynı bilgileri tekrarlayıp ezberleme ihtimali ve bellek problemi ortadan kaldırılmış, genişliği artırılarak da daha az filtrelemeye ihtiyaç duyulup hesaplama maliyeti düşürülmüş olunur. VGG modelinden daha hızlı olup AlexNet’ten ise 12 kat fazla parametre içerir. GoogleNet modelinin mimari yapısı 22 katmandan oluşup görselleri tanımada %93 oranında başarıya sahiptir. Şekil 2.7.’de GoogleNet’e ait model mimarisi gösterilmektedir (Özkan & Ülker, 2017; Szegedy ve ark., 2015).



Şekil 2.7. GoogleNet’e ait model mimarisi

2.3.3.4. YOLO (You Only Look Once) ve YOLOv8


Nesneleri tespit etmede yeni ve hızlı bir ESA modeli olan YOLO, ilk olarak 2016 yılında Redmon ve ark. (2016) tarafından tanıtılmıştır. Nesne tespiti için gerçek zamanlı yaklaşım sunan YOLO, görüntüdeki nesnelerin bir bakışta tespit edilebilmesini ve bu hıza erişmeyi amaçlamaktadır.

YOLO’da kullanılan evrimsel sinir ağı nesneleri tespit edip, konumlarını belirlemektedir. Kullanılacak verinin görüntüsünü belirlenmiş boyutlarda böler ve oluşturulan her bir parça için birden fazla kutu oluşturur. Oluşan bu kutuların her biri nesnenin olası bir bölgesini temsil eder. Her bir sınırlı kutu için sınıf olasılıkları çıktı olarak elde edilir.

YOLOv8 görüntülerin sınıflandırılması, nesne tespiti ve segmentasyon gibi görevleri yerine getiren YOLO algoritma serisinin en son versiyonudur (Jocher ve ark., 2023). YOLO’nun önceki sürümlerindeki başarıya ilave olarak yapılan iyileştirmelerle performansının artırılarak, daha hızlı hesaplama yöntemleri ile daha hassas şekilde nesnelerin algılanması amaçlanmıştır.

YOLOv8 önceki sürümlerin aksine ‘Anchor Free’ yaklaşımı kullanır yani önceden tanımlanmış referans kutuları olmadan nesnelerin doğrudan konum ve boyutlarını önceki bilgiler olmadan tahmin eder.

YOLOv8’de mozaik veri büyütme ile eğitim verileri çeşitlendirilir. Girdi olarak alınan görüntüler birden fazla parçaya bölünerek mozaik görüntüde rastgele birleştirilip yeni eğitim modelleri oluşturulur. Böylelikle mozaik büyütme ile YOLOv8’in nesne algılamada genelleme yaparak daha iyi öğrenmesi sağlanır. Ayrıca verinin az olduğu durumlarda bile performansı yüksektir. Bu iyileştirmeler, modelin öğrenmesini ve hızlı şekilde doğru çıkarımlar yapmayı sağlar (Chabi Adjobo ve ark., 2023). Şekil 2.8.’de YOLOv8 model mimarisi gösterilmektedir (Ju & Cai, 2023).



Şekil 2.8. YOLOv8 model mimarisi

2.4. Diş Hekimliğinde Yapay Zekanın Kullanım Alanları

Günümüzde endüstriden ekonomiye, tarımdan mühendisliklere, sağlık hizmetlerinden sosyal ağlara kadar birçok alanda yapay zeka uygulamalarından yararlanılmaktadır. Daha az insan gücü ile daha hızlı işlem yapılabilmesi ve insan kaynaklı hata oranının az olması nedeniyle bu uygulamalar diş hekimliği alanlarında da kendilerine yer bulmuştur. Diş hekimliği uygulamalarında en doğru teşhis ile yapılacak tedavilerde en iyi sonucu almak amacıyla yapay zeka uygulamalarından yararlanılmaktadır (Miloglu ve ark., 2022). Bu alanda yapılan ilk çalışma 1989 yılında geliştirilen "Oral Radiograph Diagnosis (ORAD)" isimli yazılım programıdır. Kemik içi lezyon bulunan 98 hastanın klinik ve radyolojik verileri girilerek hekimin ayırıcı tanıda dikkat etmesi gereken durumlar listelenip tanıda yardımcı olunması amaçlanmıştır (White, 1989). Günümüze kadar diş hekimliği alanında yapay zeka ile birçok çalışma

yapılmış ve klinik uygulamalarda her geçen gün umut vadeden sonuçlar elde edilmeye başlanmıştır.

Evrişimsel sinir ağları kullanılarak, ağız içi kameralar ile alınan görüntülerde ve intraoral radyografilerde çürük tespitleri yapılmıştır (Lee ve ark., 2018a; Moutselos ve ark., 2019). Kompozit ve amalgam gibi restoratif materyallerde döner aletlerin oluşturduğu sesler yapay zeka programları ile analiz edilerek gereksiz doku kaybının önlenmesini amaçlayan çalışmalar mevcuttur (Zakeri ve ark., 2014). Dental röntgenlerden white spoot lezyonlarının tespit edilmesi için derin öğrenme yöntemleri kullanılmış ve ortalama %81-84'lük başarı elde edilmiştir (Askar ve ark., 2021).

Yapay sinir ağları kullanılarak radyografilerden apikal foramenin tespit edildiği bir çalışmada %93 başarı oranına (Saghiri ve ark., 2012), intraoral dijital radyografilerden vertikal kök kırıklarının belirlendiği başka bir çalışmada da %97'lik başarı oranına ulaşılabilmiştir (Kositbowornchai ve ark., 2013). Görüntü işleme yazılım programları ile ağız içi video kayıtlarından kanal ağızlarının lokalizasyonunun yapılabildiği (Bruellmann ve ark., 2013), derin evrişimsel sinir ağları ile CBCT görüntülerinden periapikal lezyonların tespit edilebildiği (Orhan ve ark., 2020), panoramik radyografiler üzerinde ekstra kök ve kanal varlığının belirlenebildiği çalışmalar da mevcuttur (Hiraiwa ve ark., 2019).

CBCT görüntüleri üzerinde dişsiz sahalardaki alveoler kemik seviyesinin belirlenmesinde kullanılan bir yapay zeka yönteminin %95 oranında başarı sergilediği (Kurt Bayrakdar ve ark., 2021), destek vektör makinaları gibi denetimli öğrenme sistemleri ile periodontal hastalıkların tespitinde %88 oranında başarının elde edildiği çalışmalar da mevcuttur (Farhadian ve ark., 2020). İmplant işlemlerinin cerrahi operasyon öncesi planlamasında, peri-implantitis durumlarında kemik kaybının saptanmasında, periodontal hastalıktan dolayı prognozu kötü olan dişlerin

belirlenmesinde, intraoral fotoğraflardan periodontal enflamasyonların tespitinde yapay zeka yöntemlerinden yararlanılmaktadır (Lee ve ark., 2018b; Rana ve ark., 2017).

Ortodontik tedavi öncesi farklı maloklüzyonlara sahip hastaların çekimli veya çekimsiz tedaviye karar verilmesinde yapay zeka yöntemlerinden yararlanılmış ve %80 başarı ile doğru teşhis konulmuştur (Xie ve ark., 2010). Yapay zeka algoritmaları ile sefalometrik filmlerden boyun vertebralarındaki referans noktaları ile hastanın iskeletsel olgunlaşması ve büyüme-gelişim evrelerinin belirlenmesi (Kök ve ark., 2019), evrişimsel sinir ağları ile sefalometrik noktaların otomatik ölçümleri yapılarak iskeletsel maloklüzyonların teşhisi (Yu ve ark., 2020), makine öğrenimi ile lateral sefalometrik röntgenlerden ortognatik cerrahi planlanacak vakaların tespiti (Choi ve ark., 2019) gibi literatürdeki birçok çalışma yapay zeka kullanımına örnek olarak verilebilmektedir.

İnley ve onley gibi protez parçalarının üretim aşamasında (Ender ve ark., 2011), gülüş tasarımı (Gurel, 2020), kuron preparasyonlarında, protezlerin tam oturması ve kenar uyumunda bilgisayar destekli teknolojilerin kullanımı (Wang ve ark., 2014), diş hekimliği branşında yapay zekanın başka bir atılımı olmuştur.

Pediyatrik diş tedavilerinde kooperasyon problemi olduğu için hızlı ve etkili tedaviler başarı oranını artırmaktadır. CNN algoritmaları kullanılarak hastalardan alınan radyografilerden süt dişleri, gömük süt dişleri ve meziodensler tespit edilmiş (Ha ve ark., 2021) ve daha az hata oranı ile hızlı şekilde teşhise varılması amaçlanmıştır (Miloglu ve ark., 2022). Pediyatrik hastalardan alınmış 4518 adet panoramik radyografi üzerinde yapılan bir çalışmada CNN tabanlı YOLOv4 modeli kullanılarak daimi diş germelerinin %94 doğrulukla tespit edilebildiği gösterilmiştir (Kaya ve ark., 2022). Yapılan başka bir çalışmada erken çocukluk çağı çürüklerine sahip 3 ile 5 yaş aralığındaki 6404 çocuk klinik, demografik, davranışsal ve ebeveyn tarafından bildirilen ağız sağlığı durumlarına göre makine öğrenmesi ile sınıflandırıldı. Klinik muayeneden bağımsız, çocukların

yaşları ve ebeveynlerin ağız sağlığı konusundaki bilgilerini içeren ikili parametrelerin kullanıldığı makine öğreniminin erken çocukluk çağı çürüklerinin olasılığını yüksek doğrulukla tahmin ettiği belirlenmiştir (Karhade ve ark., 2021).

2.4.1. Ağız Diş ve Çene Radyolojisi Alanında Yapay Zeka Uygulamaları

Diş hekimliğinde klinik muayenelere ek olarak teşhisi kolaylaştırmak için alınan radyografik görüntüler, intraoral, ekstraoral ve histolojik kesitlerin fotoğrafları, CBCT, MR ve USG görüntüleri gibi verilerin fazlalığından dolayı, YZ çalışmaları dental radyoloji alanında da hız kazanmıştır. Hastalardan alınan görüntülerden YZ yöntemleri ile teşhise yönelik çok sayıda çalışma mevcut iken, görüntüleri işleme, raporlama, adli tıp gibi alanlarda da bu yöntemlerden yararlanılmıştır (Pauwels, 2021).

Dental radyografiler ve bazı görüntüleme yöntemleri üzerinde dişleri numaralandırabilen ve sınıflandırma yapabilen çalışmalar yapılmıştır (Tuzoff ve ark., 2019; Wirtz ve ark., 2018). Panoramik radyografiler üzerinde dişlerin numaralandırılmasına yönelik yapılan bir çalışmada, eğitilen model %98 hassasiyetle uzman görüşüne benzer doğruluk payı sergilemiştir (Bilgir ve ark., 2021). Başka bir çalışmada ise CBCT görüntülerinde sınıflandırma yapabilen ve %91 doğruluğa ulaşan derin CNN modeli geliştirilmiştir (Miki ve ark., 2017).

Çok katmanlı sinir ağı kullanılarak 160 adet bitewing radyografinin bir olduğu veri setinde, yapay zeka modülünün aproksimal çürük teşhisindeki başarısı %88 olarak bulunmuştur (Devito ve ark., 2008). Yapılan başka bir çalışmada ise bitewing radyografiler ile dişlerin numaralandırılması ve sınıflandırılması yapılmış, kuron boyu, pulpaya ait özellikler, pulpa odasının yükseklik-genişlik oranları, destek vektör makinesi (SVM) algoritmaları ile değerlendirilmiştir (Lin ve ark., 2010).

TME disfonksiyonu bulunan 290 hasta ile disfonksiyonu taklit eden 29 hastanın karşılaştırıldığı bir çalışmada bu iki durumun ayırt ediciliğinde yapay zeka tabanlı

modeller kullanılmış, hastaların kelime kullanım sıklığı ve ağız açma boyutuna göre farklılıkları ortaya çıkarılarak, klinik karar ve prognoz aşamasında hekime yardımcı olabileceği gösterilmiştir (Nam ve ark., 2018).

Son zamanlarda osteoporozun tanısı için geliştirilen bilgisayar destekli sistemler erken tanı konulmasında umut vadetmektedir. Panoramik radyografiler üzerinde transfer öğrenme stratejileri kullanılarak yapılan bir çalışmada, 680 adet panoramik görüntü üzerinde osteoporoz sınıflandırılması yapılmış ve sistemlerin %85 oranında doğruluk payına ulaştığı bildirilmiştir (K.-S. Lee ve ark., 2020).

YZ yöntemleri ile dental radyografik görüntülerden yaş tahmini yapılan çalışmalar da mevcuttur. Çek nüfusundaki 3-17 yaş arası 1393 bireyin panoramik radyografilerinde mandibuladaki dişlerin gelişim evrelerine 'data mining' yöntemi ile bakılarak yaş tahmini yapılmıştır (Velemínská ve ark., 2013).

Yapılan başka bir çalışmada Sjögren sendromu doğrulanmış 25 hastaya ait BT görüntüleri üzerinde derin öğrenme sistemlerinin doğru teşhisteki performansı değerlendirilmiş, %96 oranında doğruluk elde edildiği bildirilmiştir (Kise ve ark., 2019).

Panoramik radyografilerde maksiller sinüslerin lokalizasyonları, sinüs içindeki lezyonları ve maksillar sinüzitleri tespit etmek için CNN modelleri kullanılarak yapılan çalışmalarda, YZ sistemlerinin hekimlere göre daha yüksek performans sergilediği bildirilmiştir (Kuwana ve ark., 2021; Murata ve ark., 2019).

Panoramik radyografiler kullanılarak kist ve tümörlerin ayrımı için SVM tabanlı YZ modelleri kullanılmış, kist ve tümör ayrımında %87 oranında doğruluk elde edildiği bildirilmiştir (Nurtanio ve ark., 2013). Başka bir çalışmada da CBCT görüntülerinden oluşan bir veri seti kullanılmış, periapikal kist ve keratokistik odontojenik tümör ayrımı için SVM tabanlı sınıflandırma yapılarak yüksek başarı elde edilmiştir (Yılmaz ve ark., 2017). Keratokistik odontojenik tümör ve ameloblastoma lezyonlarını içeren 500 adet

panoramik radyografi üzerinde lezyonları tespit edebilecek CNN modelleri geliştirilmiş ve %83 doğruluğa ulaşılmıştır (Poedjiastoeti & Suebnukarn, 2018). Arji ve ark. (2019) yaptığı bir çalışmada, histopatolojik olarak tanısı doğrulanmış belirli patolojik oluşumları panoramik radyografilerde sadece mandibulada izlenen radyolusent lezyonlar olarak, derin öğrenme yöntemiyle tespit etmeye ve sınıflandırmaya çalışmış, en başarılı sonucu dentigeröz kistler için elde ettiklerini bildirmişlerdir. Benzer bir çalışmada da panoramik radyografilerden oluşan 412 adet veri setinde sadece maksillar bölgedeki kistik lezyonların tespit edilmesinde derin öğrenme yönteminin performansı araştırılmış ve %75-77 oranında başarılı bulunduğu bildirilmiştir (Watanabe ve ark., 2021). CBCT ve panoramik radyografi görüntülerinden oluşan veri setinin kullanıldığı diğer bir çalışmada, CNN modelleri ile 3 tip odontojenik kistik lezyonun tespit ve teşhisi değerlendirilmiş ve CBCT görüntülerinde daha yüksek performans elde edildiği bildirilmiştir (J. H. Lee ve ark., 2020).

Derin evrişimsel sinir ağlarının eğitilmesi ile lenf nodu metastazı ve ektranodal yayılımları mükemmel sonuçlarla tanımlayabilen YZ çalışmaları da mevcuttur (Kann ve ark., 2018). Oral skuamoz hücreli karsinom tanısı konulmuş 45 hastanın BT görüntülerinden oluşan veri seti ile derin öğrenme yönteminin servikal lenf nodu metastazı tanısındaki performansı değerlendirilmiş, %78 oranında doğruluk elde edildiği bildirilmiştir (Ariji, Fukuda, ve ark., 2019).

Radyolojik muayenelerle doğru tanıya ulaşabilmek için radyografik görüntülerin de belirli bir kalitede ve standartlarda olması önemlidir. Bu amaçla radyolojik verilerin iyileştirilmesine yönelik yapılmış YZ çalışmaları da mevcuttur. Hastaların konumlandırma hatasına bağlı olarak panoramik radyografilerde oluşan bulanıklığı gidermek için CNN modellerinin geliştirildiği bir çalışmada, konumlandırma hatasını tahmin edebilen ve görüntüyü yeniden yapılandırabilen bir YZ yöntemi başarılı

bulunmuştur (Du ve ark., 2018). BT görüntülerindeki artefaktları azaltarak yüksek kaliteli görüntüleri elde etmeyi amaçlayan ve bu amaçla da evrimsel sinir ağlarını eğiterek başarılı sonuç elde edebilen çalışmalar da mevcuttur (Hu ve ark., 2019).



3. MATERİYAL VE METOT

3.1. Etik Kurul Onayı

Bu tez çalışması; 2022-2024 yılları arasında Atatürk Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı'nda yürütülmekte olup, çalışmanın bilimsel etik kurallarına uygunluğu Atatürk Üniversitesi Diş Hekimliği Fakültesi Etik Kurulu'nun 02/12/2022 tarih, 11/2022 sayı ve 89 nolu kararı ile onaylanmıştır (EK-2). Çalışma, Helsinki Deklarasyonu ilkelerine göre yapılmıştır.

3.2. Çalışmanın Dizaynı

Çalışmamızda, arşiv kayıtları kullanılarak panoramik radyografiler üzerinde maksillofasial bölgede radyopak ve radyolusent görüntü veren lezyonların tespiti, sınıflandırılması ve segmentasyonu, derin öğrenme modellerinden AlexNet, VGG16, GoogleNet ve YOLOv8 kullanılarak değerlendirildi. Derin öğrenme analiz yöntemi olarak denetimli öğrenme algoritması kullanıldı. Yani algoritmalar giriş verileriyle eşleştirilmiş doğru çıkışları kullanarak bir model oluşturdu. Böylelikle modellerin, daha önceden görülmemiş yeni verilerle girişlerin çıktılarını tahmin edebilmesi sağlandı. Kullanılan derin öğrenme modellerinin radyografik veriler üzerinde lezyonların tespit edilebilirliğindeki başarılarının belirlenmesi amaçlandı.

3.3. Hastaların Seçimi

Çalışmaya; Atatürk Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı'na başvuran, maksillofasial bölgede mevcut bulunan lezyonların tespiti için alınan panoramik radyografiler ve rutin radyografik muayene esnasında tesadüfi olarak lezyon rastlanan hastalar arasından 12-80 yaş aralığındaki bireylerin panoramik radyografileri dahil edildi.

Ocak 2020-Aralık 2022 tarihleri arasında alınan tüm CBCT arşiv görüntüleri retrospektif olarak incelendi. Lezyon teşhisi konmuş veya görüntüleme alanlarında

tesadüfi olarak lezyon tespit edilen hastaların panoramik filmleri de çalışmaya dahil edildi. Toplamda 500 adet panoramik radyografi üzerinde 415 tanesi radyolusent, 235 tanesi radyopak olmak üzere 650 adet lezyon uzmanlık eğitiminde bulunan bir gözlemci tarafından değerlendirildi. 500 adet lezyon içermeyen sağlıklı panoramik görüntü de lezyon var-yok sınıflaması yapabilmek için çalışmaya dahil edildi. Lezyonların sınıflandırılması, tespit edilmesi ve segmentasyonunda YZ algoritmalarının başarısı değerlendirildi.

Hastaların çalışmaya dahil edilme kriterleri:

- Radyolojik muayene sonucunda maksillofasial bölgede radyopak veya radyolusent görüntü veren lezyona sahip olan,
- Sadece ortodontik aparey ve cerrahi operasyonlarda kullanılan materyaller gibi metal artefaktına sebep olabilecek enstrüman bulundurmayan,
- Lezyonların sınırlarının net olarak belirlenebilmesi için hareket artefaktının daha az görülebilme ihtimali bulunan ve cinsiyet fark etmeksizin 12-80 yaş aralığında olan bireyler,
- Karışık dişlenme dönemindeki daimi diş germelerinin lezyon görüntüleri ile karışmaması açısından 12 yaş ve üzerinde olan bireyler,
- Panoramik ve CBCT görüntüleri incelemeye uygun ve yeterli kalitede olan bireyler çalışmaya dahil edilmiştir.

Hastaların çalışmamıza dahil edilmeme kriterleri:

- Malign, agresif yapıda, trabeküler kemik içerisine invaze olmuş, sınırları belirlenemeyen lezyonlara sahip olan,
- Radyopak ve radyolusent sınırları net olarak ayırt edilemeyen, mikst görüntüye sahip lezyonları içeren,

- Hasta veya çekim kaynaklı artefakt (metal artefaktı, çekim sırasında hasta pozisyonundan kaynaklı artefaktlar, hareket artefaktı vb. sebeplerden meydana gelen bozukluklar) bulunan,
- İncelenecek alanın bütünüyle görüntülenmesine imkân vermeyecek kraniyo fasial deformiteye sahip hastalara ait panoramik radyografiler çalışmaya dahil edilmemiştir.

3.4. Klinik ve Radyolojik Verilerin Kaydedilmesi

Bu tez çalışması için, Atatürk Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı'na rutin dental muayene için başvuran veya dış merkezlerce lezyon teşhisi için yönlendirilen hastalardan Planmeca Promax 2D Panoramic System (Planmeca, Helsinki, Finlandiya) ile elde edilen dijital panoramik görüntüler kullanıldı. Hastaların vücut kütlesi, kemik yoğunluğu ve anatomik yapılarına göre ekspozür parametreleri manuel ayarlanabilmekle beraber, ortalama 4 mA, 62 kVP ve 16,2 sn'de elde edilen görüntüler, her hasta için aynı radyoloji teknisyeni tarafından elde edildi. Panoramik radyografilerin standardizasyonunda; üretici firmanın önerdiği referans noktalarına uyularak, hastanın sagittal düzlemi yere dik, Frankfurt düzlemi yere paralel olacak şekilde ve servikal vertebraların mandibula üzerine süperpozisyonunu önlemek amacıyla hastalar ski pozisyonuna uygun bir şekilde konumlandırılarak görüntüler elde edildi (Şekil 3.1.). Bununla birlikte daha önceden NewTom FP (Quantitative Radiologyha, Verona, Italy) ile alınmış CBCT görüntülerinden lezyon teşhisi konulmuş hastalara ait olan ve hastane otomasyon sisteminde mevcut bulunan panoramik görüntüler de çalışmaya dahil edildi.



Şekil 3.1. Dijital panoramik radyogramda radyoopak ve radyolusent lezyon alanları izleniyor

Panoramik görüntüleri elde edilen hastaların adı ve soyadı, doğum tarihleri, radyogram üzerinde hangi tür ve kaç adet lezyona sahip olduklarını belirten veriler kaydedilip tablo haline getirildi. Hastaların panoramik görüntüleri windows bitmap (.bmp) formatında indirilip, lezyon ile alakalı algoritmalar (tespiti, türü) kaydedildi. Çalışmada kullanılacak veriler, 11 yıllık deneyime sahip ve uzmanlık eğitiminde bulunan bir diş hekimi tarafından değerlendirildi.

Lezyonların dansitelerinin değerlendirilmesinde, çevre yumuşak dokuların dansitesi esas alındı. Çevre yumuşak dokuya göre daha yoğun izlenen lezyonlar radyoopak (Şekil 3.2.), çevre yumuşak dokuya göre daha düşük yoğunluğa sahip alanları gösteren lezyonlar radyolusent olarak kabul edildi (Şekil 3.3) (Bayrakdar, 2015).



Şekil 3.2. Panoramik radyogramda radyoopak görüntü veren lezyon izleniyor




Şekil 3.3. Panoramik radyogramda radyolusent görüntü veren lezyon izleniyor


3.5. Görüntülerin Etiketlenmesi

Panoramik radyogramlarda izlenen lezyonlar, araştırmacı tarafından serbest çizim tekniği denilen başka bir ifade ile de poligon yöntemi kullanılarak etiketlendi. Etiketleme için typescript programlama dilinde yazılan ve görüntü etiketleme işleminde yaygın, ücretsiz ve çevrimiçi olarak kullanılabilen Make Sense AI 1.11.0-alpha (GPL-3.0 Lisans) programı kullanıldı. Etiketleme işlemi, lezyonların radyoopak ve radyolusent görüntü özelliğine göre farklı renklerde ve lezyonun sınırlarını tamamıyla içerisine alacak şekilde

yapıldı (Şekil 3.4 ve Şekil 3.5.). Elde edilen etiketli görüntüler json formatında dışa aktarıldı ve etiketlenen alanların koordinatlarını içeren label dosyaları oluşturuldu.



Şekil 3.4. Panoramik radyogramda radyolusent görüntü veren lezyonun Makesense AI programı ile etiketlendiği izleniyor



Şekil 3.5. Panoramik radyogramda radyoopak görüntü veren lezyonun Makesense AI programı ile etiketlendiği izleniyor

Tüm deneysel çalışmalar, Python ve MATLAB programlama dilinde 128 GB rastgele erişim belleğine ve 2 adet grafik işlem birimine (GeForce RTX 2080 TITAN; NVIDIA) sahip 64 bit Ubuntu 18.04 sistemi üzerinde gerçekleştirildi.

3.6. Veri Setlerinin Oluřturulması

Yapay zeka ile sınıflandırma, nesneleri tespit etme, segmentasyon, karar verme ve çözümlleme gibi birçok işlem yapılabilir (Casalegno ve ark., 2019). Bu görevleri yapabilmeleri için yapay zeka algoritmaları, denetimli öğrenme olarak bilinen her bir görüntüye karşılık gelen bir sonuç ve veri çiftlerinden elde edilen verilerle eğitilir (Schwendicke ve ark., 2019).

Bu tez çalışmasında da maksillofasial bölgede radyopak ve radyolusent görüntü veren lezyonların derin öğrenme modelleri ile belirlenmesinde, lezyonların sınıflandırılması, lezyonların tanımlanması ve görüntü bölütleme olmak üzere 3 ayrı veri seti oluşturularak probleme 3 tür yaklaşım sergilenmiştir.

3.6.1. Sınıflandırma-Classification

Sınıflandırma iki şekilde yapıldı;


1. Panoramik radyografilerin bütününde radyopak veya radyolusent lezyon varlığının anlaşılabilirliğine bakıldı. Bu sınıflandırmada 4 kategori mevcuttur.

PR'nin bütünü verilerek sınıflandırma


- Lezyon var-Lezyon yok (2 sınıf)
- Radyopak-Radyolusent (2 sınıf)
- Radyopak-Radyolusent-Radyopak/Radyolusent (3 sınıf)
- Radyopak-Radyolusent-Radyopak/Radyolusent-Lezyon yok (4 sınıf)

2. Radyopak ve radyolusent lezyonların ayırt ediciliğine, panoramik radyogramın bütününde lezyon olan bölgenin kırılması ile bakıldı. Verilerin ön hazırlık aşamasında panoramik görüntülerde segmentasyon etiketlerine göre sınırlayıcı kutu koordinatları otomatik olarak belirlendi. Sınıflandırma


işleminde ilgili nöral ağın (network) giriş boyutuna göre bir kodla otomatik olarak yeniden boyutlandırıldı (Şekil 3.6, Şekil 3.7 ve Şekil 3.8).



Şekil 3.6. Evrişimsel sinir ağları ile lezyon sınıflandırmasının akışı izleniyor




Şekil 3.7. Radyoopak lezyonlara ait veri setleri izleniyor



Şekil 3.8. Radyolusent lezyonlara ait veri setleri izleniyor

Sınıflandırma problemlerinin tamamında AlexNet, VGG16 ve GoogleNet derin öğrenme modellerinden yararlanıldı.

10 Fold Cross Validation yani 10 Kat Çarpraz Doğrulama yöntemi ile veri seti 10 eşit parçaya bölündü (Şekil 3.9). Ardından 9 parçası eğitim verisi ve her bir parça sırasıyla test verisi olarak kullanılırken kalan diğer 9 parça her defasında eğitim verisi olarak tekrar kullanıldı. Bu işlem toplamda on kez tekrarlandı ve her seferinde farklı bir parça test verisi olarak seçildi. Elde edilen test sonuçlarının ortalaması alınarak modellerin genel performansı değerlendirildi. Böylelikle modelin aşırı uydurma olasılığı (tahminden sapma) azaltılarak performans ölçüm güvenilirliği artırılmaya çalışıldı.




Şekil 3.9. 10 kat çarpraz doğrulama yöntemi izleniyor

3.6.2. Nesne Tanıma-Object Detection

Panoramik radyografilerin bütünü üzerinde radyoopak veya radyolusent lezyonlu olan bölgelerin konumlarının tespit edilebilirliğine bakıldı. Makesense AI programı ile etiketlenen lezyon alanlarını içeren panoramik görüntülerle etiket dosyaları hazırlanarak nesne tespiti için derin öğrenme modellerinden olan YOLOv8 (n-s-m-l-xl) kullanıldı (Şekil 3.10.) Çalışma için üç ayrı veri seti oluşturuldu. Eğitim veri seti (train), modelin öğrenme süreci için kullanılmış olup, toplam veri kümesinin %70'ini oluşturmaktadır. Doğrulama veri seti (validation), eğitim sürecinde modelin genelleme yeteneğini belirlemek için kullanılır ve %15'lik veri kümesi içerir. Test veri seti ise eğitilmiş modelin performansını değerlendirmek için kullanılmış olup, toplam veri kümesinin %15'ini oluşturmaktadır. Nesne tespitinde elimizdeki veri setini oluşturan toplamda 500 adet panoramik görüntüden 350 tanesi eğitim verisi, 75 tanesi doğrulama veri seti ve 75 tanesi de test veri seti olarak kullanıldı. Veri kümesinde bulunan 235 adet radyoopak lezyonun 170 tanesi eğitim verisi, 26 tanesi doğrulama verisi, 39 tanesi de sisteme ilk kez girdisi olacak şekilde test verisi, 415 adet radyolusent lezyonun 295 tanesi eğitim verisi, 62 tanesi doğrulama verisi ve 58 tanesi de test verisi olarak ayarlandı. Toplamda ise, 650 adet lezyonun 465 tanesi eğitim verisi, 88 tanesi doğrulama verisi ve 97 tanesi de sisteme ilk kez girdisi olacak şekilde test verisi olarak ayarlandı (Tablo 3.1).

Tablo 3.1. Nesne tanıma probleminde veri dağılımı


Lezyonlu bölge	Train	Validation	Test	Toplam
PR	350	75	75	500
Radyoopak	170	26	39	235
Radyolusent	295	62	58	415
Toplam	465	88	97	650



Şekil 3.10. Nesne tespitinde hazırlanan etiket dosyaları izleniyor

3.6.3. Segmentasyon-Görüntü Bölütleme

Tüm panoramik radyografi üzerinde radyopak ve radyolusent lezyonların konumları ve hangi piksellerin lezyon alanı olduğunun tespit edilebilirliğine bakıldı. Yöntem olarak YOLOv8 (n-s-m-l-xl) kullanıldı. Görüntüde ilk olarak potansiyel sınırlayıcı kutular (Bbox) oluşturuldu. Verilerin ön hazırlık aşamasında panoramik radyografi görüntülerine uygun olacak şekilde, yapılan etiketlere göre sınırlayıcı kutu koordinatları otomatik olarak belirlendi. Ardından bu kutular üzerinde sınıflandırmalar yapıldı. Görüntü alanındaki her piksele belirli bir sınıf atandı ve her nesnenin ana hatlarını belirlemede piksel düzeyinde hassasiyet sağlanarak karmaşık yapıda olan lezyonların daha iyi anlaşılması amaçlandı. Tek bir evrişimsel ağ ile aynı anda birden fazla sınırlayıcı kutular ve bu kutular için sınıf olasılıklarını belirlemede YOLO son derece hızlı ve basit şekilde uygulandı. Modelin eğitimi panoramik radyografilerin bütünü üzerinde yapıldı (Şekil 3.11).



Şekil 3.11. Radyolusent lezyonun segmentasyonu izleniyor

3.7. Algoritma Performanslarının Değerlendirilme Metrikleri

Konfüzyon matrisi diğer adıyla karışıklık veya hata matrisi; gerçek değerlerin bilindiği bir dizi test verisi üzerinde, doğru ve yanlış tahmin edilen pikselleri gösteren ve algoritmanın performansını tanımlamak için kullanılan istatistiksel tablodur. Konfüzyon matrisi ikili sınıflandırma görevlerinde, sınıflandırıcının tahmin ettiği değerler ile gerçek değerleri gösteren, 2x2 boyutunda olan bir tablodur (Şekil 3.12). İkiden fazla sınıfın olduğu durumlarda bu tablo genişletilebilir. Bu tez çalışmasında da sınıflandırma probleminde tahmin ve gerçek değerlerin birbirleriyle karşılaştırılması için konfüzyon matrisi kullanılarak yapay zeka modellerinin performansı değerlendirildi.

GERÇEK DEĞERLER

		GERÇEK DEĞERLER	
		POZİTİF(1)	NEGATİF(0)
TAHMİN DEĞERLERİ	POZİTİF(1)	TRUE POSİTİVE (TP)	FALSE POSİTİVE (FP)
	NEGATİF(0)	FALSE NEGATİVE (FN)	TRUE NEGATİVE (TN)

Şekil 3.12. Konfüzyon matris tablosu

True Positive (TP): 1 olarak sınıflandırdığımız ve gerçekten de 1 olan değerlerin sayısıdır. Yani gerçek değer ve tahmin değeri aynıdır.

False Positive (FP): 1 olarak sınıflandırdığımız fakat gerçekte 0 olan değerlerin sayısıdır. Tahminde olan ama gerçekte olmayan değeri ifade eder.

True Negative (TN): 0 olarak sınıflandırdığımız ve gerçekten de 0 olan değerlerin sayısıdır. Yani tahminde de gerçekte de olmayan değeri ifade eder.

False Negative (FN): 0 olarak sınıflandırdığımız fakat gerçekte 1 olan değerlerin sayısıdır. Tahminde olmayıp gerçekte olan değeri tanımlar.

Oluşturulan veri setlerinin sınıflandırma performanslarını değerlendirmede konfüzyon matrisinden hesaplanan bazı oranlar vardır (J.-H. Lee ve ark., 2020). Bunlar;

Doğruluk (Accuracy): Sınıflandırma problemlerinde doğru tahminlerin toplamının, toplam veri kümesine olan oranıdır. Modelin ne sıklıkta doğru tahmin ettiğinin bir göstergesidir.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

Kesinlik (Precision): Pozitif olarak tahmin ettiğimiz değerlerin içinde gerçek doğruların ne kadar bulunduğunu, pozitif tahminlerin başarısını gösterir.

$$Precision = \frac{TP}{TP + FP}$$

Duyarlılık (Recall): Pozitif olarak tahmin edilmesi gereken değerlerin ne kadarının pozitif olarak tahmin edildiğini gösterir. Sadece pozitif değerlerden doğru sınıflandırılanların oranını verir.

$$Recall = \frac{TP}{TP + FN}$$

F1 Skoru: Recall ve precision değerlerinin harmonik ortalaması ile hesaplanan değerdir. Sınıflandırıcının performansının ne kadar iyi olduğunu göstergesidir ve sınıflandırıcıları karşılaştırmak için kullanılmaktadır.

$$F1\ score = 2 * \frac{precision * recall}{precision + recall}$$

Çalışmamızdaki modellerin lezyon varlığı ve türünü sınıflandırmadaki başarısını değerlendirmek için kullanılan matrisler aşağıdaki gibidir:


True Positive (TP): Lezyonun varlığı ve hangi tür lezyon olduğu doğru tespit edildi. Yani lezyon gerçekte varsa var, radyoopak ise radyoopak, radyolusent ise radyolusent olarak doğru tahmin edildi.

False Positive (FP): Lezyon olmayan durumlarda varmış gibi kabul edip ve türleri de yanlış tespit edildi. Yani, gerçekte lezyon yok ama tahmini değerlerde lezyon var ve gerçekte opak olan lezyon tahmini değerlerde lusent olarak tespit edildi.

True Negative (TN): Lezyon olmayan durumları ve türleri doğru tespit edildi. Örneğin gerçekte radyopak olmayan etiket tahmininde de radyopak olmadığı belirlendi.

False Negative (FN): Lezyonların varlığı ve türleri doğru tespit edilemedi. Gerçekte radyopak olan lezyonun tahmininde radyolusent olduğu belirlendi.

Nesne tespiti ve segmentasyon problemlerinde modellerin performansını değerlendirmek için precision-recall grafiğinden yararlanılmaktadır. Precision, doğru pozitif tahminlerin toplam pozitif tahminlere oranını ifade ederken, recall doğru pozitif tahminlerin gerçek pozitiflere oranıdır. Precision-recall eğrisinde, daha yüksek precision ve recall değerlerine sahip olan noktalara yakın olduğunda modelin performansı daha iyi demektir. Bu durum modelin doğru pozitifleri artırdığı ve yanlış pozitifleri azalttığı anlamına gelir. Şekil 3.13'deki eğride, radyolusent lezyonların tespitinde modelin performansının radyopaklara göre daha iyi olduğu görülmektedir.



Şekil 3.13. Precision recall (kesinlik duyarlılık) grafiği

4. BULGULAR

4.1. Derin Öğrenme Mimarilerinin Performans Sonuçları

Çalışmamızda maksillofasial bölgede radyoopak ve radyolusent görüntü veren lezyonlar için 3 temel problem ele alınmıştır. Bu problemlerin birincisi lezyonların sınıflandırılmasıdır ve bu iki şekilde yapılmıştır. Birincisi, panoramik radyografilerin bütünü üzerinde radyoopak veya radyolusent lezyon varlığının anlaşılabilirliğine bakılmıştır. İkincisi ise panoramik radyografinin lezyon içeren bölgesi kırılarak lezyonların ayırt ediciliğinde sınıflandırma modellerinin başarısı ölçülmüştür. Lezyonlar için ikinci problem, panoramik radyografide radyoopak veya radyolusent lezyonlu alanların konumlarının tespit edilmesidir. Üçüncü problem ise radyografik görüntülerde hangi piksel alanının hangi lezyona ait olduğunun belirlenmesidir. Her üç problem için de farklı derin öğrenme mimarileriyle çalışılmış ve her model için konfüzyon matrisler ile precision recall grafiği kullanılarak performans değerlendirilmiştir.

4.1.1. Maksillofasial Bölgede Radyoopak ve Radyolusent Görüntü Veren Lezyonların Sınıflandırılmasında Derin Öğrenme Mimarilerinin Performans Sonuçları

Çalışmamızda sınıflandırma problemine ilk yaklaşımda panoramik radyografilerin bütünü üzerinde radyoopak ve radyolusent lezyonların varlığının belirlenmesinde AlexNet, VGG16 ve GoogleNet olmak üzere 3 ayrı derin öğrenme mimarisinin başarısı araştırıldı.

Panoramik radyografilerin bütünü üzerinde yapılan sınıflandırmada;

- Lezyon var-Lezyon yok (2 sınıf)
- Radyoopak -Radyolusent (2 sınıf)
- Radyoopak -Radyolusent – Radyoopak/Radyolusent (3 sınıf)
- Radyoopak -Radyolusent – Radyoopak/Radyolusent- Lezyon yok (4 sınıf)


Üç farklı derin öğrenme modeli her bir sınıflama için ayrı ayrı olacak şekilde ve her bir yöntem 10 kere çalıştırılarak toplamda 120 deney yapıldı. Bu modeller ile elde edilen sonuçlarda yüksek doğruluk oranlarına ulaşıldı. Her bir model için ayrı ayrı konfüzyon matrisleri kullanılarak modellerin performanslarındaki başarı değerlendirildi.

Şekil 4.1, şekil 4.2. ve şekil 4.3’de panoramik radyografilerin bütünü üzerinde lezyon varlığı ve yokluğunun gerçek ve tahmini değerlerinin dağılımını gösteren üç farklı derin öğrenme mimarisine ait konfüzyon matrisleri verilmektedir. Konfüzyon matrisleri incelendiğinde, AlexNet mimarisinde normalde lezyon olan 500 adet veriden 471 tanesini YZ tespit edebilmişken, 29 tanesini lezyon var olduğu halde yanlış tahmin etmiştir. Diğer yandan lezyon olmayan 500 adet veriden 463 tanesini YZ lezyon yok olarak doğru şekilde tespit ederken, lezyon bulundurmayan 37 tane görüntü lezyon var şeklinde yanlış olarak tahmin edilmiştir. AlexNet modelinin lezyon var sınıfındaki tahmin başarısı %94.2 iken, lezyon yok sınıfındaki başarısı %92.6’dır (Şekil 4.1).

		alexnet		
Output Class	lesion	471 47.1%	37 3.7%	92.7% 7.3%
	no lesion	29 2.9%	463 46.3%	94.1% 5.9%
		94.2% 5.8%	92.6% 7.4%	93.4% 6.6%
		lesion	no lesion	Target Class

Şekil 4.1. Lezyon var-yok sınıflamasında AlexNet modeline ait konfüzyon matrisi


Aynı sınıflandırma işlemi için VGG16 mimarisi kullanılmış ve modele ait konfüzyon matrisi incelendiğinde normalde lezyon olan 500 adet veriden, 348 tanesini YZ tespit edebilmişken, 152 tanesini lezyon var olduğu halde yanlış tahmin etmiştir. Diğer yandan lezyon olmayan 500 adet veriden, YZ 299 tanesini lezyon yok olarak doğru şekilde tespit etmişken, 201 tane lezyon bulundurmayan görüntüyü, var şeklinde yanlış olarak tahmin etmiştir. VGG16 modelinin lezyon var sınıfındaki tahmin başarısı %69.6 iken, yok sınıfındaki başarısı %59.8'dir (Şekil 4.2).



Şekil 4.2. Lezyon var-yok sınıflamasında VGG16 modeline ait konfüzyon matrisi

Son olarak bu sınıflama için GoogleNet modeli kullanılmış ve normalde lezyon olan 500 adet veriden, 470 tanesini YZ tespit edebilmişken, 30 tanesini lezyon var olduğu halde yanlış tahmin etmiştir. Diğer yandan lezyon olmayan 500 adet veriden, 486 tanesini YZ lezyon yok olarak doğru şekilde tespit etmişken, 14 tane lezyon bulundurmayan görüntüyü ise lezyon var şeklinde yanlış olarak tahmin etmiştir. GoogleNet modelinin

lezyon var sınıfındaki tahmin başarısı %94 iken, yok sınıfındaki başarısı %97.2'dir (Şekil 4.3).



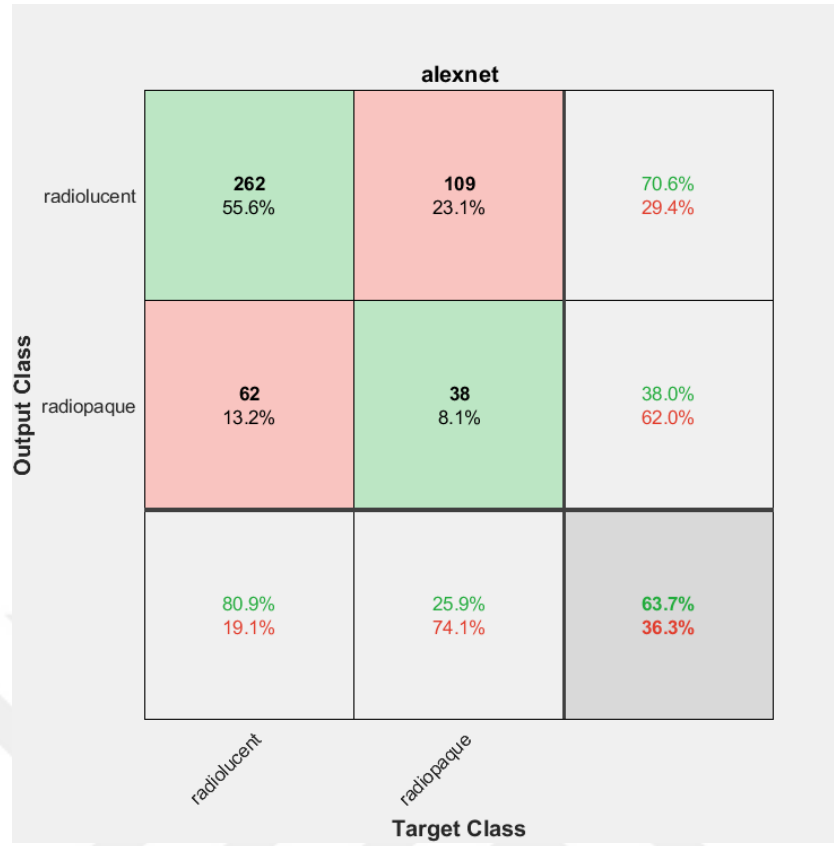
Şekil 4.3. Lezyon var-yok sınıflamasında GoogleNet modeline ait konfüzyon matrisi

AlexNet modelinin lezyon var-yok sınıflamasındaki oransal performansının %93.4 doğruluk, %92.7 kesinlik, %94.2 duyarlılık ve %93.4 F1 puanı sergilediğini göstermiştir. VGG 16 modelinin lezyon var-yok sınıflamasındaki oransal performansının %64.7 doğruluk, %63.3 kesinlik, %69.6 duyarlılık ve %66.2 F1 puanı sergilediğini göstermiştir. GoogleNet modelinin lezyon var-yok sınıflamasındaki oransal performansının %95.6 doğruluk, %97.1 kesinlik, %94 duyarlılık ve %95.5 F1 puanı sergilediğini göstermiştir. Buna göre panoramik radyografilerin bütünü üzerinde lezyon var-yok ikili sınıflamasında en başarılı model GoogleNet iken, en düşük başarı oranları ise VGG 16 ile elde edilmiştir (Tablo 4.1).

Tablo 4.1. Lezyon var yok sınıflamasında kullanılan yöntemlerin karşılaştırması

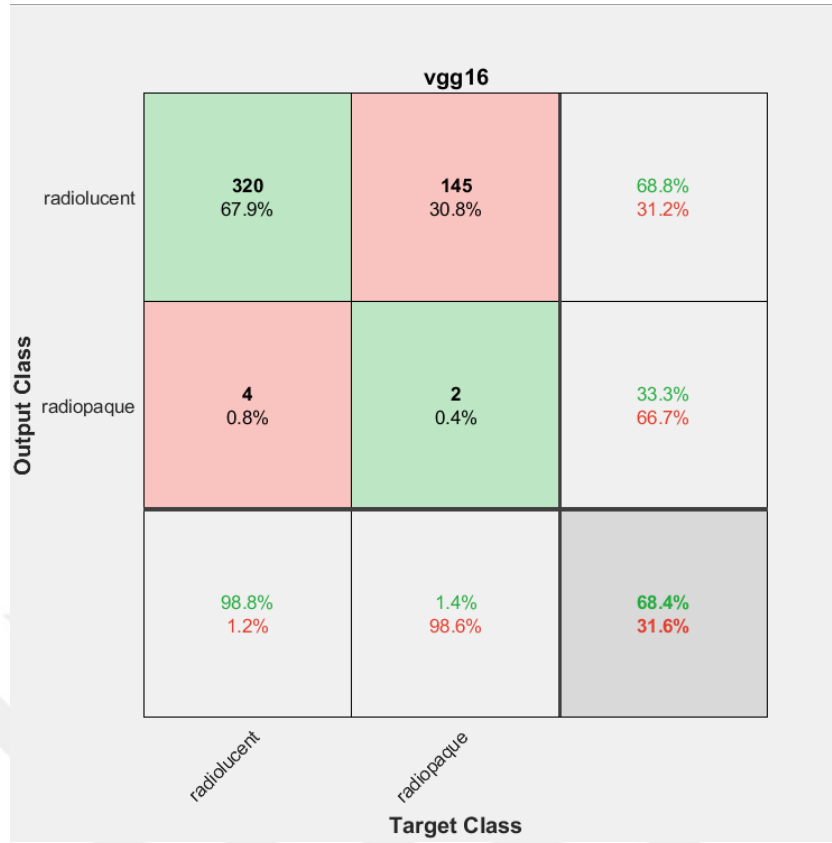
	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 Puan (%)
AlexNet	93.4	92.7	94.2	93.4
VGG16	64.7	63.3	69.6	66.2
GoogleNet	95.6	97.1	94	95.5

Panoramik radyografilerin bütünü üzerindeki sınıflandırmaya ait ikinci yaklaşım, lezyonun radyopak ve radyolusent ayrımıdır. Şekil 4.4, Şekil 4,5 ve Şekil 4,6'da panoramik radyografilerin bütünü üzerinde, radyopak ve radyolusent lezyonların gerçek ve tahmini değerlerinin dağılımını gösteren 3 derin öğrenme mimarisine ait konfüzyon matrisleri verilmektedir. Konfüzyon matrisi incelendiğinde AlexNet mimarisinde normalde radyolusent lezyon içeren 324 adet veriden, 262 tanesini YZ tespit doğru edebilmişken, 62 tanesini radyolusent lezyon olduğu halde yanlış tespit etmiştir. Diğer yandan radyopak lezyon içeren 147 adet veriden 38 tanesini YZ radyopak olarak doğru şekilde tespit edebilmişken, 109 tane radyopak görüntüyü radyolusent olarak yanlış tespit etmiştir. AlexNet modelinin radyopak ve radyolusent lezyon sınıflamasındaki tahmin başarısı, radyolusent lezyonlar için %80.9 iken, radyopak lezyonlar için %25.9'dur (Şekil 4.4).



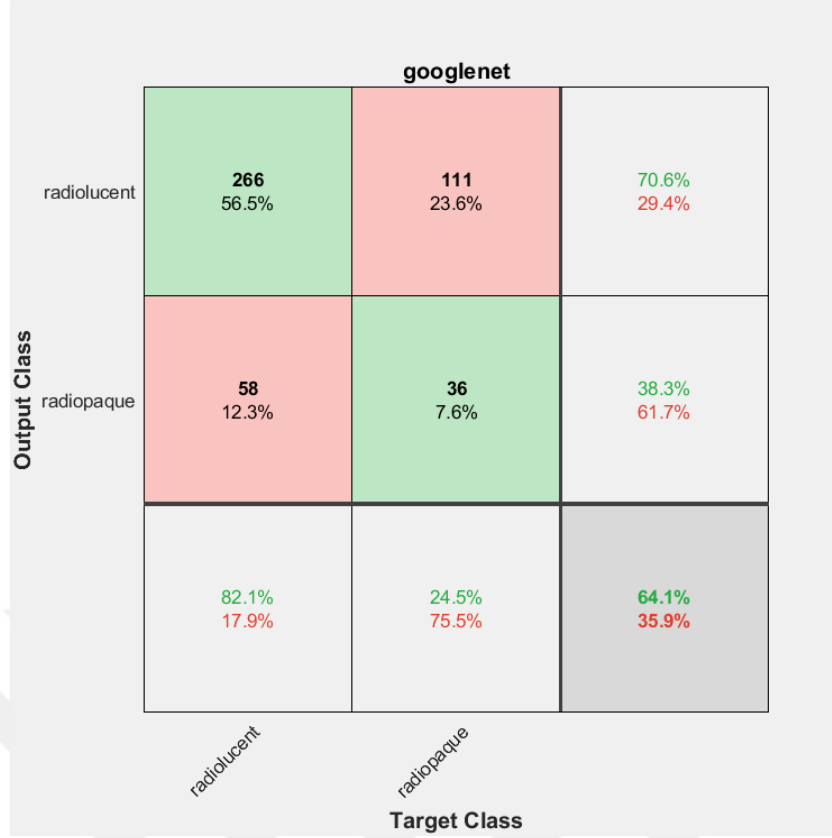
Şekil 4.4. Radyoopak ve radyolusent lezyon sınıflamasında AlexNet modeline ait konfüzyon matrisi

VGG16 mimarisi kullanılarak yapılan bu sınıflamada, normalde radyolusent olan 324 adet veriden, 320 tanesini YZ doğru tespit edebilmişken, 4 tanesini radyolusent lezyon olduğu halde yanlış tespit etmiştir. Diğer yandan radyoopak olan 147 adet lezyondan, 2 tanesini YZ radyoopak olarak doğru şekilde tespit etmişken, 145 tane radyoopak görüntüyü ise radyolusent olarak yanlış tespit etmiştir. VGG 16 modelinin radyoopak ve radyolusent lezyon sınıflamasındaki tahmin başarısı, radyolusent lezyonlar için %98.8’lik oranla en yüksek başarıyı sergilemişken, radyoopak lezyonlar için ise %1.4’lük oranla en düşük başarı elde edilmiştir (Şekil 4.5).



Şekil 4.5. Radyopak ve radyolusent lezyon sınıflamasında VGG16 modeline ait konfüzyon matrisi

Son olarak aynı sınıflama için GoogleNet mimarisi kullanılmış ve normalde radyolusent olan 324 adet veriden, 266 tanesini YZ doğru tespit edebilmişken, 58 tanesini radyolusent lezyon olduğu halde yanlış tespit etmiştir. Diğer yandan radyopak olan 147 adet lezyondan, 36 tanesini YZ radyopak olarak doğru şekilde tespit etmişken, 111 tane radyopak görüntüyü radyolusent olarak yanlış tespit etmiştir. GoogleNet modelinin radyopak ve radyolusent lezyon sınıflamasındaki tahmin başarısı, radyolusent lezyonlar için %82.1 iken, radyopak lezyonlar için %24.5'tir (Şekil 4.6).



Şekil 4.6. Radyopak ve radyolusent lezyon sınıflamasında GoogleNet modeline ait konfüzyon matrisi

Elde edilen verilere göre AlexNet modelinin radyopak-radyolusent lezyon sınıflamasındaki oransal performansının %63.7 doğruluk, %70.6 kesinlik, %80.8 duyarlılık ve %75.3 F1 puanı sergilediğini göstermiştir. VGG 16 modelinin radyopak-radyolusent lezyon sınıflamasındaki oransal performansının %68.4 doğruluk, %68.8 kesinlik, %98.8 duyarlılık ve %81 F1 puanı sergilediğini göstermiştir. GoogleNet modelinin radyopak-radyolusent lezyon sınıflamasındaki oransal performansının ise %64.1 doğruluk, %70.5 kesinlik, %82 duyarlılık ve %75.8 F1 puanı sergilediğini göstermiştir. Buna göre panoramik radyografilerin bütünü üzerinde radyopak radyolusent lezyon sınıflamasında en yüksek başarı oranları VGG 16 modeli ile elde edilmiştir (Tablo 4.2).

Tablo 4.2. Radyoopak ve radyolusent lezyon sınıflamasında kullanılan yöntemlerin karşılaştırması

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 Puan (%)
AlexNet	63.7	70.6	80.8	75.3
VGG16	68.4	68.8	98.8	81
GoogleNet	64.1	70.5	82	75.8

Panoramik radyografilerin bütünü üzerinde sınıflandırmaya ait üçüncü yaklaşım ise tüm PR’lerde radyoopak, radyolusent ve radyoopak-radyolusent lezyonların varlığının belirlendiği 3 sınıflı problemidir. Şekil 4.7, Şekil 4.8 ve Şekil 4.9’da panoramik radyografilerin bütünü üzerinde radyoopak, radyolusent ve radyoopak-radyolusent lezyonların varlığının gerçek ve tahmini değerlerinin dağılımını gösteren üç derin öğrenme mimarisine ait konfüzyon matrisleri verilmektedir. AlexNet mimarisine ait konfüzyon matrisi incelendiğinde, normalde radyolusent lezyon içeren 324 adet veriden 233 tanesini YZ doğru tespit edebilmişken, 67 tanesinde radyolusent lezyon olduğu halde radyoopak olarak, 24 tanesinde ise radyolusent lezyon olduğu halde radyoopak-radyolusent olarak yanlış tahmin etmiştir. Diğer yandan radyoopak ve radyolusent lezyonun beraber görüldüğü 29 adet lezyondan, 6 tanesini YZ doğru şekilde tespit ederken, 17 tane görüntüyü radyolusent şeklinde, 6 tane görüntüyü radyoopak şeklinde yanlış olarak tahmin etmiştir. Çalışmada değerlendirilen 147 adet radyoopak lezyon içeren görüntüden 39 tanesini YZ radyoopak lezyon olarak doğru şekilde tespit ederken, 6 tane görüntüyü radyoopak-radyolusent görüntü şeklinde, 102 tane görüntüyü ise radyolusent şeklinde yanlış olarak tahmin etmiştir. AlexNet modelinin radyoopak, radyolusent ve radyoopak-radyolusent lezyon sınıflamasındaki tahmin başarısı, radyolusent lezyonlar için %71.9, radyoopak lezyonlar için %26.5 ve radyoopak-radyolusent lezyonların bulunduğu görüntülerdeki başarısı %20.7’dir (Şekil 4.7).

		AlexNet			
Output Class	radiolucent	233 46.6%	17 3.4%	102 20.4%	66.2% 33.8%
	radiolucent+radiopaque	24 4.8%	6 1.2%	6 1.2%	16.7% 83.3%
	radiopaque	67 13.4%	6 1.2%	39 7.8%	34.8% 65.2%
		71.9% 28.1%	20.7% 79.3%	26.5% 73.5%	55.6% 44.4%
		radiolucent	radiolucent+radiopaque	radiopaque	
		Target Class			

Şekil 4.7. Radyopak, radyolusent ve radyopak-radyolusent lezyon sınıflamasında AlexNet modeline ait konfüzyon matrisi

3 sınıflı bu probleme yaklaşımda VGG16 mimarisine ait konfüzyon matrisi incelendiğinde, normalde radyolusent lezyon içeren 324 adet veriden, 260 tanesini YZ doğru tespit edebilmişken, 64 tanesinde radyolusent lezyon olduğu halde radyopak olarak yanlış tahmin etmiştir. Diğer yandan radyopak-radyolusent lezyonun beraber görüldüğü 29 adet lezyonu YZ hiçbir şekilde tespit edememişken, 23 tane görüntüyü radyolusent şeklinde, 6 tane görüntüyü ise radyopak şeklinde yanlış olarak tahmin etmiştir. Çalışmada değerlendirilen 147 adet radyopak lezyon içeren görüntüden 30 tanesini YZ doğru olarak tespit ederken, 117 tane görüntüyü ise radyolusent olarak yanlış tahmin etmiştir. VGG16 modelinin radyopak, radyolusent ve radyopak-radyolusent lezyon sınıflamasındaki tahmin başarısı, radyolusent lezyonlar için %80.2, radyopak lezyonlar için %20.4'tür. Fakat radyopak-radyolusent lezyonların bulunduğu görüntülerde ise tamamen başarısız olduğu (%0) görüldü (Şekil 4.8).

		vgg16			
Output Class	radiolucent	260 52.0%	23 4.6%	117 23.4%	65.0% 35.0%
	radiolucent+radiopaque	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	radiopaque	64 12.8%	6 1.2%	30 6.0%	30.0% 70.0%
		80.2% 19.8%	0.0% 100%	20.4% 79.6%	58.0% 42.0%
		Target Class			
		radiolucent	radiolucent+radiopaque	radiopaque	

Şekil 4.8. Radyopak, radyolusent ve radyopak-radyolusent lezyon sınıflamasında VGG16 modeline ait konfüzyon matrisi

3 sınıflı bu probleme yaklaşımda GoogleNet mimarisine ait konfüzyon matrisi incelendiğinde, normalde radyolusent lezyon içeren 324 adet veriden 286 tanesini YZ doğru tespit edebilmişken, 37 tanesinde radyopak olarak, 1 tanesinde ise radyopak-radyolusent olarak yanlış tahmin etmiştir. Diğer yandan radyopak-radyolusent lezyonun beraber görüldüğü 29 adet lezyondan 1 tanesini YZ doğru olarak tespit etmişken, 26 tane görüntüyü radyolusent şeklinde, 2 tane görüntüyü de radyopak şeklinde yanlış olarak tahmin etmiştir. Çalışmada değerlendirilen 147 adet radyopak lezyon içeren görüntüden 21 tanesini YZ doğru şekilde tespit etmişken, 126 tane görüntüyü ise radyolusent şeklinde yanlış olarak tahmin etmiştir. GoogleNet modelinin radyopak, radyolusent ve radyopak-radyolusent lezyon sınıflamasındaki tahmin başarısı, radyolusent lezyonlar için %88.3, radyopak lezyonlar için %14.3 ve radyopak-radyolusent lezyonların bulunduğu görüntülerdeki başarısı ise %3.4'tür (Şekil 4.9).

		googlenet			
Output Class	radiolucent	286 57.2%	26 5.2%	126 25.2%	65.3% 34.7%
	radiolucent+radiopaque	1 0.2%	1 0.2%	0 0.0%	50.0% 50.0%
	radiopaque	37 7.4%	2 0.4%	21 4.2%	35.0% 65.0%
		88.3% 11.7%	3.4% 96.6%	14.3% 85.7%	61.6% 38.4%
		Target Class			
		radiolucent	radiolucent+radiopaque	radiopaque	

Şekil 4.9. Radyopak, radyolusent ve radyopak-radyolusent lezyon sınıflamasında GoogleNet modeline ait konfüzyon matrisi

Elde edilen verilere göre AlexNet modelinin 3 sınıflı problemdeki oransal performansının %55.6 doğruluk, %66.2 kesinlik, %71.9 duyarlılık ve %68.9 F1 puan gösterdiği, VGG 16 modelinin ise %58 doğruluk, %65 kesinlik, %80.2 duyarlılık ve %71.8 F1 puan sergilediğini göstermiştir. GoogleNet modelinin 3 sınıflı bu problemdeki oransal performansının ise %61.6 doğruluk, %65.3 kesinlik, %88.3 duyarlılık ve %75 F1 puan gösterdiği ve bu problemdeki en yüksek başarıyı da GoogleNet' in sergilediği tespit edilmiştir (Tablo 4.3).

Tablo 4.3. Radyoopak, radyolusent ve radyoopak-radyolusent lezyon sınıflamasında kullanılan yöntemlerin karşılaştırması

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 Puan (%)
AlexNet	55.6	66.2	71.9	68.9
VGG16	58	65	80.2	71.8
GoogleNet	61.6	65.3	88.3	75

Panoramik radyografilerin bütünü üzerinde lezyonların sınıflandırılmasına yönelik probleme son yaklaşım ise 4 sınıftan oluşmaktadır. Veri dağılımı; radyoopak, radyolusent, radyoopak-radyolusent birlikte ve lezyon bulundurmayan veriler şeklindedir. Şekil 4.10, Şekil 4.11 ve Şekil 4.12’de panoramik radyografilerin bütünü üzerinde lezyonlara ait gerçek ve tahmini değerlerinin dağılımını gösteren üç derin öğrenme mimarisine ait konfüzyon matrisleri verilmektedir. Konfüzyon matrisi incelendiğinde AlexNet mimarisinde gerçekte lezyon bulunmayan 500 adet veriden 423 tanesinde YZ lezyon bulamayarak doğru tespit edebilmiş, gerçekte 324 adet radyolusent lezyon içeren veriden 222 tanesinde radyolusent lezyonu bulabilmiş, gerçekte 29 adet radyoopak-radyolusent lezyon içeren veri setinden yalnızca 1 tanesinde doğru tespit edebilmiş ve gerçekte 147 adet radyoopak lezyon içeren veri setinden ise 37 tanesinde radyoopak lezyonu doğru tahmin etmiştir. AlexNet modelinin radyoopak, radyolusent, radyoopak-radyolusent ve lezyon bulundurmayan verilerdeki tahmin başarısı, radyolusent lezyonlar için %68.5, radyoopak lezyonlar için %25.2, radyoopak-radyolusent lezyonların bulunduğu görüntülerde %3.4, lezyon bulundurmayan görüntülerde ise %84.6’dır (Şekil 4.10).

		alexnet				
Output Class	no lesion	423 42.3%	20 2.0%	4 0.4%	11 1.1%	92.4% 7.6%
	radiolucent	54 5.4%	222 22.2%	16 1.6%	95 9.5%	57.4% 42.6%
	radiolucent+radiopaque	5 0.5%	6 0.6%	1 0.1%	4 0.4%	6.3% 93.8%
	radiopaque	18 1.8%	76 7.6%	8 0.8%	37 3.7%	26.6% 73.4%
	84.6% 15.4%	68.5% 31.5%	3.4% 96.6%	25.2% 74.8%	68.3% 31.7%	
		Target Class				
		no lesion	radiolucent	radiolucent+radiopaque	radiopaque	

Şekil 4.10. Radyoopak, radyolusent, radyoopak-radyolusent ve lezyon yok sınıflamasında AlexNet modeline ait konfüzyon matrisi

4 sınıflı bu probleme yaklaşımda VGG16 mimarisine ait konfüzyon matrisi incelendiğinde gerçekte lezyon bulundurmayan 500 adet veriden 443 tanesinde YZ lezyon bulamayarak doğru tespit edebilmiş, gerçekte 324 adet radyolusent lezyon içeren veriden 255 tanesinde radyolusent lezyonu bulabilmiş, gerçekte 29 adet radyoopak-radyolusent lezyon içeren veri setinden doğru tahmini hiç yapamamış ve gerçekte 147 adet radyoopak lezyon içeren veri setinden ise 8 tanesinde radyoopak lezyonu doğru tahmin etmiştir. VGG16 modelinin radyoopak, radyolusent, radyoopak-radyolusent ve lezyon bulundurmayan verilerdeki tahmin başarısı, radyolusent lezyonlar için %78.7, radyoopak lezyonlar için %5.4, lezyon bulundurmayan görüntülerde ise %88.6'dır. Fakat radyoopak-radyolusent lezyonların bulunduğu görüntülerde ise tamamen başarısız olduğu (%0) görüldü (Şekil 4.11).

		vgg16				
Output Class	no lesion	443 44.3%	62 6.2%	6 0.6%	29 2.9%	82.0% 18.0%
	radiolucent	57 5.7%	255 25.5%	21 2.1%	110 11.0%	57.6% 42.4%
	radiolucent+radiopaque	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	radiopaque	0 0.0%	7 0.7%	2 0.2%	8 0.8%	47.1% 52.9%
		88.6% 11.4%	78.7% 21.3%	0.0% 100%	5.4% 94.6%	70.6% 29.4%
		Target Class				
		no lesion	radiolucent	radiolucent+radiopaque	radiopaque	

Şekil 4.11. Radyoopak, radyolusent, radyoopak-radyolusent ve lezyon yok sınıflamasında VGG16 modeline ait konfüzyon matrisi

4 sınıflı bu probleme yaklaşımda GoogleNet mimarisine ait konfüzyon matrisi incelendiğinde, gerçekte lezyon bulundurmayan 500 adet veriden, 496 tanesinde YZ lezyon bulamayarak doğru tespit edebilmiş, gerçekte 324 adet radyolusent lezyon içeren veriden 227 tanesinde radyolusent lezyonu bulabilmiş, gerçekte 29 adet radyoopak-radyolusent lezyon içeren veri setinden doğru tahmini hiç yapamamış ve gerçekte 147 adet radyoopak lezyon içeren veri setinden ise 34 tanesinde radyoopak lezyonu doğru tahmin etmiştir. GoogleNet modelinin radyoopak, radyolusent, radyoopak-radyolusent ve lezyon bulundurmayan verilerdeki tahmin başarısı, radyolusent lezyonlar için %70.1 radyoopak lezyonlar için %23.1, lezyon bulundurmayan görüntülerde ise en yüksek tahminle %99.2'dir. Fakat radyoopak-radyolusent lezyonların bulunduğu görüntülerde ise tamamen başarısız olduğu (%0) görüldü (Şekil 4.12).

		googlenet				
Output Class	no lesion	496 49.6%	28 2.8%	3 0.3%	11 1.1%	92.2% 7.8%
	radiolucent	3 0.3%	227 22.7%	20 2.0%	102 10.2%	64.5% 35.5%
	radiolucent+radiopaque	0 0.0%	1 0.1%	0 0.0%	0 0.0%	0.0% 100%
	radiopaque	1 0.1%	68 6.8%	6 0.6%	34 3.4%	31.2% 68.8%
		99.2% 0.8%	70.1% 29.9%	0.0% 100%	23.1% 76.9%	75.7% 24.3%
		Target Class				
		no lesion	radiolucent	radiolucent+radiopaque	radiopaque	

Şekil 4.12. Radyoopak, radyolusent, radyoopak-radyolusent ve lezyon yok sınıflamasında GoogleNet modeline ait konfüzyon matrisi

Elde edilen verilere göre AlexNet modelinin 4 sınıflı problemdeki oransal performansının %68.3 doğruluk, %92.4 kesinlik, %84.6 duyarlılık ve %88.3 F1 puan gösterdiği, VGG 16 modelinin ise %70.6 doğruluk, %82 kesinlik, %88.6 duyarlılık ve %85.1 F1 puan sergilediğini göstermiştir. GoogleNet modelinin 4 sınıflı bu problemdeki oransal performansının ise %75.7 doğruluk, %92.2 kesinlik, %99.2 duyarlılık ve %95.5 F1 puan gösterdiği ve bu problemdeki en yüksek başarıyı da GoogleNet'in sergilediği tespit edilmiştir (Tablo 4.4).

Tablo 4.4. Radyoopak, radyolusent, radyoopak-radyolusent ve lezyon yok sınıflamasında kullanılan yöntemlerin karşılaştırması

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 Puan (%)
AlexNet	68.3	92.4	84.6	88.3
VGG16	70.6	82	88.6	85.1
GoogleNet	75.7	92.2	99.2	95.5

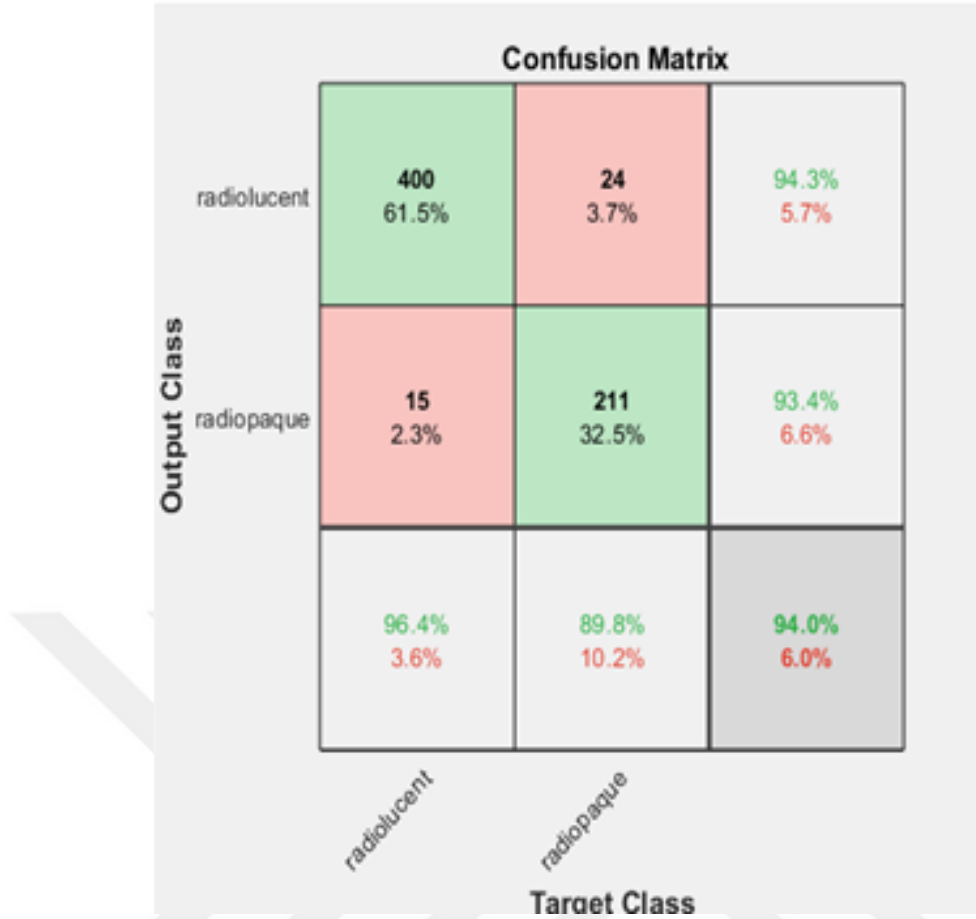
Çalışmamızda sınıflandırma problemine ikinci yaklaşım olarak radyoopak ve radyolusent lezyonların ayırt ediciliğine, panoramik radyografilerin sadece lezyon olan bölgesinin kırılması ile bakılmıştır. Bu yaklaşımda 3 yöntem kullanılmıştır. Bunlar; GoogleNet, AlexNet ve VGG16'dır. Her bir yöntem 10 kere çalıştırılarak toplamda 30 deney yapılmıştır. Her bir model için ayrı ayrı konfüzyon matrisleri kullanılarak modellerin performanslarındaki başarıları değerlendirilmiştir.

Şekil 4.13, Şekil 4.14 ve Şekil 4.15'de panoramik radyografilerin sadece kırılmış bölgeleri üzerinde radyoopak ve radyolusent lezyonların gerçek ve tahmini değerlerinin dağılımını gösteren 3 derin öğrenme mimarisine ait konfüzyon matrisleri verilmektedir. Konfüzyon matrisi incelendiğinde, AlexNet mimarisinde normalde radyolusent lezyon içeren 415 adet veriden 400 tanesini YZ doğru tespit edebilmişken, 15 tanesini radyolusent lezyon olduğu halde yanlış tespit etmiştir. Diğer yandan radyoopak lezyon içeren 235 adet veriden 227 tanesini YZ radyoopak olarak doğru şekilde tespit etmişken, 8 tane radyoopak görüntüyü radyolusent olarak yanlış tespit etmiştir. AlexNet modelinin radyoopak ve radyolusent lezyon sınıflamasındaki tahmin başarısı radyolusent lezyonlar için %96.4 iken, radyoopak lezyonlar için %96.6'dır (Şekil 4.13).

		Confusion Matrix		
Output Class	radiolucent	400 61.5%	8 1.2%	98.0% 2.0%
	radiopaque	15 2.3%	227 34.9%	93.8% 6.2%
		96.4% 3.6%	96.6% 3.4%	96.5% 3.5%
		radiolucent	radiopaque	
		Target Class		


Şekil 4.13. Kırpılmış panoramik radyografilerde radyoopak ve radyolusent lezyon sınıflamasında AlexNet modeline ait konfüzyon matrisi

Konfüzyon matrisi incelendiğinde, VGG16 mimarisinde normalde radyolusent lezyon içeren 415 adet veriden 400 tanesini YZ doğru tespit edebilmişken, 15 tanesini radyolusent lezyon olduğu halde yanlış tespit etmiştir. Diğer yandan radyoopak lezyon içeren 235 adet veriden 211 tanesini YZ radyoopak olarak doğru şekilde tespit etmişken, 24 tane radyoopak görüntüyü radyolusent olarak yanlış tespit etmiştir. VGG 16 modelinin radyoopak ve radyolusent lezyon sınıflamasındaki tahmin başarısı, radyolusent lezyonlar için %96.4 iken, radyoopak lezyonlar için %89.8'dir (Şekil 4.14).



Şekil 4.14. Kırpılmış panoramik radyografilerde radyoopak ve radyolusent lezyon sınıflamasında VGG16 modeline ait konfüzyon matrisi

Son olarak aynı sınıflama için konfüzyon matrisi incelendiğinde, GoogleNet mimarisinde normalde radyolusent lezyon içeren 415 adet veriden 407 tanesini YZ doğru olarak tespit edebilmişken, 8 tanesini radyolusent lezyon olduğu halde yanlış tespit etmiştir. Diğer yandan radyoopak lezyon içeren 235 adet veriden 220 tanesini YZ radyoopak olarak doğru şekilde tespit etmişken, 15 tane görüntüyü radyolusent olarak yanlış tespit etmiştir. GoogleNet modelinin radyoopak ve radyolusent lezyon sınıflamasındaki tahmin başarısı radyolusent lezyonlar için %98.1 iken, radyoopak lezyonlar için %93.6'dır (Şekil 4.15).



Şekil 4.15. Kırpılmış panoramik radyografilerde radyoopak ve radyolusent lezyon sınıflamasında GoogleNet modeline ait konfüzyon matrisi

Şekil 4.16’da PR’lerde kırpılmış lezyon alanları içerisinde lezyon çeşidine göre yapılan ikili sınıflandırmada, farklı modellerin tahminlerini bir araya getirerek oluşturulan son tahmin yani gerçek ve tahmini değerlerinin dağılımını gösteren *majority voting fusion* yaklaşımıyla elde edilen sonuçlar konfüzyon matrisi ile verilmektedir. Konfüzyon matrisi incelendiğinde, normalde radyolusent lezyon alanı içeren 415 tane veriden 413 tanesini YZ doğru olarak tespit edebilmişken, 2 tanesini radyolusent lezyon olduğu halde yanlış tespit etmiştir Bununla birlikte radyoopak lezyon içeren 235 adet veriden 222 tanesini YZ radyoopak olarak doğru şekilde tespit etmişken, 13 tane görüntüyü radyolusent olarak yanlış tespit etmiştir. YZ’nin radyoopak ve radyolusent lezyon sınıflamasındaki tahmin başarısı, radyolusent lezyonlar için %99.5 iken, radyoopak lezyonlar için %94.5’tir. Buna göre en yüksek tahmin başarısı radyolusent lezyon sınıfında elde edilmiştir.

Majority Voting Confusion Matrix			
Output Class	radiolucent	radiopaque	
	413 63.5%	13 2.0%	96.9% 3.1%
	2 0.3%	222 34.2%	99.1% 0.9%
	99.5% 0.5%	94.5% 5.5%	97.7% 2.3%
	radiolucent	radiopaque	
	Target Class		

Şekil.4.16. PR’lerde kırılmış lezyon alanları içerisinde lezyon çeşidine göre yapılan ikili sınıflandırmada, majority voting yaklaşımıyla elde edilen sonuçlara ait konfüzyon matrisi

Elde edilen sonuçlara göre PR’lerde kırılmış lezyon alanları içerisinde lezyon çeşidine göre yapılan ikili sınıflandırmada, AlexNet’in sınıflamadaki oransal performansının %96.4 doğruluk, %95.9 kesinlik, %96.4 duyarlılık ve %96.2 F1 puanı sergilediğini göstermiştir. VGG16’nın sınıflamadaki oransal performansının %94 doğruluk, %93.8 kesinlik, %93 duyarlılık ve %93.4 F1 puanı sergilediğini göstermiştir. GoogleNet’in sınıflamadaki oransal performansının %96.4 doğruluk, %96.4 kesinlik, %95.8 duyarlılık ve %96.1 F1 puanı sergilediğini göstermiştir. Farklı modellerin tahminlerini bir araya getirerek oluşturulan majority voting fusion yaklaşımıyla elde edilen sonuçlar göre ise YZ’nin bu ikili sınıflamadaki oransal performansının %97.7 doğruluk, %98 kesinlik, %96.9 duyarlılık ve %97.5 F1 puanı sergilediğini göstermiştir. (Tablo 4.5).

Tablo 4.5. PR’lerde kırpılmış lezyon alanları içerisinde, lezyon çeşidine göre yapılan ikili sınıflandırmada kullanılan yöntemlerin karşılaştırması

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 Puan (%)
AlexNet	96.4	95.9	96.4	96.2
VGG16	94	93.8	93	93.4
GoogleNet	96.4	96.4	95.8	96.1
Majority voting	97.7	98	96.9	97.5

4.1.2. Maksillofasial Bölgede Radyopak ve Radyolusent Görüntü Veren Lezyonların Tespitinde Derin Öğrenme Mimarilerinin Performans Sonuçları


Panoramik radyografi üzerinde radyopak veya radyolusent lezyonlu olan bölgenin konumlarının derin öğrenme mimarileri ile tespit edilebilirliğine bakıldı. Görüntünün bütünü içerisinde ve insan görmesi şeklinde, bir nesne hakkında nitel bilgilerin edinilmesi ve kullanılması amaçlandı. Kullanılacak olan görüntülerde aranan nesnelerin tespitinde yöntem olarak YOLOv8 (s-m-l-xl) kullanıldı. Her bir yöntem bir kez çalıştırılarak toplamda 4 deney yapıldı.

İlk yapılan deney YOLOv 8 s versiyonudur. Tablo 4.6’da mAP 50 (mean average precision) değeri, sistemin nesne tespitindeki başarı oranını vermektedir. Tespit edilen nesnenin data setinde, öğrenilmiş nesne ile bir doğruluk oranı elde edilir. YOLOv 8 s modelinin test verisi olarak kullanılan 75 adet panoramik radyografi üzerinde radyopak görüntü veren 39 adet lezyonu tespit edebilme başarısı %59.9, 58 adet radyolusent görüntü veren lezyonu tespit edebilme başarısı %69.6 ve toplamda 97 adet lezyonu tespit edebilme başarısı ise %64.8 olarak bulunmuştur (Tablo 4.6). Modelin performansını değerlendirmek için precision-recall eğrisinden yararlanılmaktadır (Şekil 4.17). Precision; doğru pozitif tahminlerin toplam pozitif tahminlere oranını ifade ederken recall; doğru pozitif tahminlerin gerçek pozitiflere oranını göstermektedir. Precision-

recall eğrisinde, daha yüksek precision ve recall değerlerine sahip olan noktalara yakın olduğunda modelin performansı daha iyi demektir. Bu durum modelin doğru pozitifleri artırdığı ve yanlış pozitifleri azalttığı anlamına gelir.

Tablo 4.6. YOLOv8 s nesne tespiti analiz sonuçları

	PR sayısı	İçerdiği lezyon	mAP50
Radyoopak		39	0.599
Radyolusent	75	58	0.696
Tüm lezyonlar		97	0.648




Şekil 4.17. YOLOv8 s modeline ait precision-recall eğrisi

Kullanılan ikinci deney versiyonu YOLOv8 m versiyonudur. Tablo 4.7’de tespit edilen nesnenin data setinde, öğrenilmiş nesne ile bir doğruluk oranı veren mAP 50 değerlerine göre, YOLOv8 m modelinin test verisi olarak kullanılan 75 adet panoramik radyografi üzerinde radyoopak görüntü veren 39 adet lezyonu tespit edebilme başarısı %65.2, 58 adet radyolusent görüntü veren lezyonu tespit edebilme başarısı %73.4 ve

toplamda 97 adet lezyonu tespit edebilme başarısı ise %69.3 olarak bulunmuştur (Tablo 4.7).

Tablo 4.7. YOLOv8 m nesne tespiti analiz sonuçları

	PR sayısı	İçerdiği lezyon	mAP50
Radyoopak		39	0.652
Radyolusent	75	58	0.734
Tüm lezyonlar		97	0.693




Şekil 4.18. YOLOv8 m modeline ait precision-recall eğrisi

Kullanılan üçüncü deney versiyonu YOLOv8 l versiyonudur. Tablo 4.8’de, tespit edilen nesnenin data setinde, öğrenilmiş nesne ile bir doğruluk oranı veren mAP 50 değerlerine göre, YOLOv8 l modelinin test verisi olarak kullanılan 75 adet panoramik radyografi üzerinde radyoopak görüntü veren 39 adet lezyonu tespit edebilme başarısı %70.2, 58 adet radyolusent görüntü veren lezyonu tespit edebilme başarısı %80.7 ve

toplamda 97 adet lezyonu tespit edebilme başarısı ise %75.4 olarak bulunmuştur (Tablo 4.8).

Tablo 4.8. YOLOv8 l nesne tespiti analiz sonuçları

	PR sayısı	İçerdiği lezyon	mAP50
Radyoopak		39	0.702
Radyolusent	75	58	0.807
Tüm lezyonlar		97	0.754




Şekil 4.19. YOLOv8 l modeline ait precision-recall eğrisi

Kullanılan dördüncü deney versiyonu YOLOv8 xl versiyonudur. Tablo 4.9’da tespit edilen nesnenin data setinde, öğrenilmiş nesne ile bir doğruluk oranı veren mAP 50 değerlerine göre, YOLOv8 xl modelinin test verisi olarak kullanılan 75 adet panoramik radyografi üzerinde radyoopak görüntü veren 39 adet lezyonu tespit edebilme başarısı %65.1, 58 adet radyolusent görüntü veren lezyonu tespit edebilme başarısı %74.7 ve

toplamda 97 adet lezyonu tespit edebilme başarısı ise %69.9 olarak bulunmuştur (Tablo 4.9).

Tablo 4.9. YOLOv8 xl nesne tespiti analiz sonuçları

	PR sayısı	İçerdiği lezyon	mAP50
Radyoopak		39	0.651
Radyolusent	75	58	0.747
Tüm lezyonlar		97	0.699



Şekil 4.20. YOLOv8 xl modeline ait precision-recall eğrisi

Panoramik radyografilerin bütünü üzerinde radyoopak veya radyolusent lezyonlu olan bölgelerin konumlarının tespit edilebilirliğinde kullanılan YOLOv8 alt modellerine ait performans başarısının karşılaştırması aşağıda verilmiştir (Tablo 4.10). Sonuç olarak, en düşük başarı oranı YOLOv8 s modeli ile en yüksek başarı oranı ise YOLOv8 l modeli ile elde edilmiştir.

Tablo 4.10. PR’lerde radyopak ve radyolusent lezyonların tespitinde kullanılan YOLOv8 modellerinin karşılaştırması

	Radyolusent	Radyopak	Tüm lezyonlar
YOLOv8 s	69.6	59.9	64.8
YOLOv8 m	73.4	65.2	69.3
YOLOv8 l	80.7	70.2	75.4
YOLOv8 xl	74.7	65.1	69.9

4.1.3. Maksillofasial Bölgede Radyopak ve Radyolusent Görüntü Veren Lezyonların Segmentasyonunda Derin Öğrenme Mimarilerinin Performans Sonuçları



Panoramik radyografilerin bütünü üzerinde radyopak ve radyolusent lezyonların konumları ve hangi piksellerin hangi lezyon alanına ait olduğunun tespit edilebilirliğine bakmak üzere YOLOv8 (n-s-m-l-xl) yöntemleri kullanıldı. Etiketlenmiş görüntülerde, YOLOv8 mimarisi ile tespit edilen nesneler bounding box işlemi (BBox) adı verilen kutular içine alındı. Sonrasında ise her bir nesnenin piksel düzeyinde lezyon sınıfları tanımlandı. Yani görüntüde bulunan tüm lezyonlar, piksel düzeyinde algılanarak lezyon türüne göre tanımlandı. Her bir yöntem ile toplamda 10 deney yapıldı.

İlk yapılan deney YOLOv 8 n versiyonudur. Tablo 4.11’de, YOLOv8 n mimarisi ile tespit edilen nesnelerin kutu içerisine alınmış halinin başarı oranları ve nesnelerin piksel düzeyindeki sınıfını tahmin etmedeki başarı oranları yani mask değerleri verilmiştir (Tablo 4.11). mAP 50 (mean average precision) değeri tespit edilen nesnenin, data setinde öğrenilmiş nesne ile doğruluk oranını vererek sistemin başarı oranını göstermektedir. YOLOv 8 n mimarisinin test verisi olarak kullanılan 75 adet panoramik radyografi üzerinde radyopak görüntü veren 39 adet lezyonun BBox ile tespitinde başarı oranı %47.1, piksel düzeyinde sınıflandırmada ise başarı oranı %50.6 olarak bulundu. Yine 58 adet radyolusent görüntü veren lezyonun hem BBox hem de piksel düzeyinde

sınıflandırıldığında %58.3 oranlarında başarı sergiledikleri görüldü. YOLOv8 n modelinin toplamda 97 adet lezyonun nesne tespitindeki başarı oranı %52.7 iken piksel düzeyindeki başarı oranı da %54.5 olarak bulundu. Modelin performansını değerlendirmek için precision-recall eğrisinden yararlanılmaktadır (Şekil 4.21).

Tablo 4.11. YOLOv8 n segmentasyon analiz sonuçları

	PR sayısı	İçerdiği lezyon	Box	mAP50	Mask	mAP50
Radyoopak	75	39	0.643	0.471	0.676	0.506
Radyolusent		58	0.717	0.583	0.719	0.583
Tüm lezyonlar		97	0.68	0.527	0.697	0.545





Şekil 4.21. YOLOv8 n bbox ve mask analiz sonuçları

Yapılan ikinci deney YOLOv8 s versiyonudur. YOLOv8 s mimarisinin test verisi olarak kullanılan 75 adet panoramik radyografi üzerinde radyoopak görüntü veren 39 adet lezyonun BBox ile tespitinde başarı oranı %57.2, piksel düzeyinde sınıflandırmada ise başarı oranı %57 olarak bulundu. Yine 58 adet radyolusent görüntü veren lezyonun BBox ile nesne tespitinde başarı oranı %65.2 iken, piksel düzeyinde sınıflandırmasında ise başarı oranı %60.9 olarak bulundu. YOLOv8 s modelinin toplamda 97 adet lezyonun nesne tespitindeki başarı oranı %61.2 iken, piksel düzeyindeki başarı oranı da %59 olarak bulundu (Tablo 4.12).

Tablo 4.12. YOLOv8 s segmentasyon analiz sonuçları

	PR sayısı	İçerdiği lezyon	Box	mAP50	Mask	mAP50
Radyoopak		39	0.755	0.572	0.755	0.57
Radyolusent	75	58	0.804	0.652	0.755	0.609
Tüm lezyonlar		97	0.78	0.612	0.755	0.59





Şekil 4.22. YOLOv8 s bbox ve mask analiz sonuçları

Yapılan üçüncü deney YOLOv8 m versiyonudur. YOLOv8 m mimarisinin test verisi olarak kullanılan 75 adet panoramik radyografi üzerinde radyoopak görüntü veren 39 adet lezyonun BBox ile tespitinde başarı oranı %67.6, piksel düzeyinde sınıflandırmada ise başarı oranı %65.8 olarak bulundu. Yine 58 adet radyolusent görüntü veren lezyonun BBox ile tespitinde başarı oranı %75.4 iken, piksel düzeyinde sınıflandırmasında ise başarı oranı %78.4 olarak bulundu. YOLOv8 m modelinin toplamda 97 adet lezyonun nesne tespitindeki başarı oranı %71.5 iken piksel düzeyindeki başarı oranı da %72.1 olarak bulundu (Tablo 4.13).

Tablo 4.13. YOLOv8 m segmentasyon analiz sonuçları

	PR	İçerdiği	Box	mAP50	Mask	mAP50
	sayısı	lezyon				
Radyoopak		39	0.759	0.676	0.768	0.658
Radyolusent	75	58	0.813	0.754	0.921	0.784
Tüm lezyonlar		97	0.786	0.715	0.844	0.721





Şekil 4.23. YOLOv8 m bbox ve mask analiz sonuçları

Yapılan dördüncü deney ise YOLOv8 l versiyonudur. YOLOv8 l mimarisinin test verisi olarak kullanılan 75 adet panoramik radyografi üzerinde radyoopak görüntü veren 39 adet lezyonun BBox ile tespitinde başarı oranı %57, piksel düzeyinde sınıflandırmada ise başarı oranı %55.4 olarak bulundu. Yine 58 adet radyolusent görüntü veren lezyonun BBox ile tespitinde başarı oranı %71.8 iken, piksel düzeyinde sınıflandırmasında ise başarı oranı %74.1 olarak bulundu. YOLOv8 l modelinin toplamda 97 adet lezyonun nesne tespitindeki başarı oranı %64.4 iken, piksel düzeyindeki başarı oranı %64.8 olarak bulundu (Tablo 4.14).

Tablo 4.14. YOLOv8 l segmentasyon analiz sonuçları

	PR sayısı	İçerdiği lezyon	Box	mAP50	Mask	mAP50
Radyoopak		39	0.615	0.57	0.615	0.554
Radyolusent	75	58	0.778	0.718	0.798	0.741
Tüm lezyonlar		97	0.696	0.644	0.707	0.648





Şekil 4.24. YOLOv8 l bbox ve mask analiz sonuçları

Segmentasyon probleminde YOLOv8 mimarisiyle yapılan son deney YOLOv8 xl versiyonudur. YOLOv8 xl mimarisinin test verisi olarak kullanılan 75 adet panoramik radyografi üzerinde radyoopak görüntü veren 39 adet lezyonun BBox ile tespitinde başarı oranı %61.4, piksel düzeyinde sınıflandırmada ise başarı oranı %54.3 olarak bulundu. Yine 58 adet radyolusent görüntü veren lezyonun BBox ile tespitinde başarı oranı %71.8 iken, piksel düzeyinde sınıflandırmasında ise başarı oranı %73.5 olarak bulundu. YOLOv8 xl modelinin toplamda 97 adet lezyonun nesne tespitindeki başarı oranı %66.6 iken piksel düzeyindeki başarı oranı %63.9 olarak bulundu (Tablo 4.15).

Tablo 4.15. YOLOv8 xl segmentasyon analiz sonuçları

	PR sayısı	İçerdiği lezyon	Box	mAP50	Mask	mAP50
Radyoopak		39	0.722	0.614	0.768	0.543
Radyolusent	75	58	0.711	0.718	0.832	0.735
Tüm lezyonlar		97	0.717	0.666	0.80	0.639




Şekil 4.25. YOLOv8 xl bbox ve mask analiz sonuçları

Panoramik radyografilerin bütünü üzerinde radyoopak veya radyolusent lezyonlu bölgelerin segmentasyonunda kullanılan YOLOv8 alt modellerine ait performans başarısının karşılaştırması aşağıda verilmiştir (Tablo 4.16).

Tablo 4.16. PR’lerde radyoopak ve radyolusent lezyonların segmentasyonunda kullanılan YOLOv8 modellerinin karşılaştırması


	Radyoopak		Radyolusent		Tüm lezyonlar	
	Box	Mask	Box	Mask	Box	Mask
YOLOv8n	47.1	50.6	58.3	58.3	52.7	54.5
YOLOv8s	57.2	57	65.2	60.9	61.2	59
YOLOv8m	67.6	65.8	75.4	78.4	71.5	72.1
YOLOv8l	57	55.4	77.8	74.1	64.4	64.8
YOLOv8xl	61.4	54.3	71.8	73.5	66.6	63.9

Elde edilen veriler doğrultusunda panoramik radyografilerin bütünü üzerinde radyoopak ve radyolusent lezyonların tespit edilmesi ve piksel düzeyinde tanımlanmasına yönelik yapılan segmentasyon çalışmasında YOLOv8 mimarisi kullanılmış ve hem bounding box yani tespit edilen nesneyi kutu içerisine alma, hem de piksel düzeyinde sınıfını tanımlama yani mask değerlerinde en iyi başarıyı gösteren mimari YOLOv8 m olmuştur. Aynı çalışmada en düşük başarıyı ise her iki grupta da YOLOv8 n modeli sergilemiştir (Şekil 4.26).




Şekil 4.26. Segmentasyon veri setine ait performans karşılaştırma grafiği


Aşağıdaki şekillerde panoramik radyografiler üzerinde radyolusent, radyoopak ve aynı panoramik görüntüde hem radyoopak hem radyolusent görüntü veren lezyonlara ait segmentasyon sonuçları gösterilmektedir (Şekil 4.27.) (Şekil 4.28.) (Şekil 4.29).



Şekil 4.27. PR’de radyolusent görüntü veren lezyonun segmentasyonu izleniyor



Şekil 4.28. PR’de radyoopak görüntü veren lezyonların segmentasyonu izleniyor



Şekil 4.29. PR’de hem radyoopak hem radyolusent görüntü veren lezyonların segmentasyonu izleniyor

5. TARTIŞMA

Maksillofasial bölge dişler, kemik doku, kıkırdak doku, sinir ve vasküler yapılar gibi çeşitli dokular barındırdığı için bu dokulardan kaynaklanan patolojik oluşumların da sıklıkla görüldüğü anatomik alanlardır. Bu patolojik oluşumların farklı dokulardan köken alması ve çeşitliliklerin olması sebebiyle etiyolojileri, klinik görünümleri, histopatolojik özellikleri ve radyografik görüntüleri gibi farklı özelliklerine göre çeşitli sınıflandırmalar yapılmıştır. Maksillofasial bölgede meydana gelen kistler, tümörler ve tümör benzeri lezyonların hem çeşitliliği hem de benzer klinik ve radyolojik özellik göstermeleri nedeniyle teşhis ve sınıflandırma hekimler için oldukça zordur (Dib ve ark., 1996).

X ışınlarının dental radyolojide kullanılması ile birlikte klinik muayeneye ek olarak radyolojik değerlendirmelerle lezyonların tanı ve teşhisi daha kolay yapılabilmektedir. Radyolojik değerlendirmede genellikle kullanılan ilk yöntem direkt grafilerdir ve en sık tercih edilen panoramik radyografiler ile dişler, destek dokular ve fasiyal bölgeye ait yapıların büyük bir kısmı hep birlikte izlenebilir. Fakat direkt grafilere lezyonların farklı düzlemlerde izlenememesi, magnifikasyonlar, geometrik distorsiyonlar, süperpozisyonlar ve düşük çözünürlük gibi dezavantajları nedeniyle ileri görüntüleme yöntemlerine ihtiyaç duyulmaktadır. BT, MRG, USG gibi tekniklerin ise maliyetleri yüksek olup, her merkezde bulunmayabilir. Ayrıca elde edilen görüntülerin yorumlanması uzman hekim ve tecrübe gerektirmektedir. Bu nedenle lezyonların otomatik olarak teşhis edilmesi için yapay zeka uygulamalarının klinik ve radyoloji pratiğinde uygulanması büyük değer taşımaktadır (Özkesici & Yılmaz, 2021). Bu tez çalışmasında klinik pratiğinde sıklıkla kullanılan panoramik radyografilerden yararlanılarak daha çok veri ile öğrenebilen yapay zeka modelleri ile maksillofasial bölgedeki lezyonların tespit edilebilirliğindeki başarı araştırılmıştır.

Literatürde yapay zeka ile dental radyolojide yapılan çalışmalara bakıldığında veri setini oluşturacak görüntü materyalleri genellikle panoramik radyografilerden ve daha az sıklıkla da CBCT görüntülerinden oluşmaktadır (Schwendicke ve ark., 2019). Radyolojik teşhiste yaygın olan panoramik radyografilerin kullanılması ve panoramik veri fazlalığından dolayı, yapay zeka tekniklerinin lezyonları daha iyi öğrenilebilmesine avantaj sağlar. Böylelikle lezyonların erken teşhisi sağlanabilir ve ileri görüntülemeye duyulan ihtiyaç azaltılabilir.

Radyolojik görüntüler üzerinde taranması ve değerlendirilmesi gereken çok sayıda anatomik yapı olmasının yanında karmaşık patolojik oluşumların teşhisinin de zor olmasına rağmen YZ uygulamaları doğru tanı oranını artırabilir (Miloglu ve ark., 2022). Yapılan bir çalışmada, çenelerde sık görülen ve radyolojik olarak benzer özellik gösteren keratokistik odontojenik tümör ve ameloblastoma gibi iki lezyonun ayrımını panoramik radyografi üzerinde yapabilen YZ modeli geliştirilmiş, CNN kullanılarak panoramik radyografiler üzerinde yapılan teşhis ile uzman radyolog tarafından yapılan teşhisin karşılaştırılabilir düzeyde bir doğruluk sergilediği gösterilmiştir (Poedjiastoeti & Suebnukarn, 2018). Yang ve ark. (2020) tarafından yapılan başka çalışmada ise maksilla ve mandibulada görülen 4 farklı kategorideki lezyonun tespitini ve sınıflandırmasını panoramik radyografi üzerinde gerçekleştirebilen derin öğrenme yöntemi geliştirilmiştir. Bu çalışma hem maksilla hem de mandibulaya ait veri setlerini içeren ve bilinen ilk çalışmadır. Yöntem olarak YOLO mimarisi kullanılmış ve histopatolojik olarak kanıtlanmış belirli lezyonlardan oluşan veri setini içermektedir. Yöntemin nesne tespitindeki doğruluk oranı ise %66 olarak belirlenmiştir. Çalışmamızda da nesne tespiti için YOLO mimarisi kullanılarak maksilla ve mandibulanın tamamı ayrıca panoramik radyografide fasiyal bölgeye ait geniş bir alan da veri setine dahil edilmiştir. Tespit edilmesi amaçlanan lezyonlar histopatolojik özelliklerine göre değil radyolojik

görüntülerde oluşturdukları dansitelere göre değerlendirilmiştir. Kullandığımız YOLO mimarisinin genel sınıflamada nesne tespitindeki doğruluk oranı ise %75.4 olarak belirlenmiştir. Daha az sayıda veri seti dahil edilmiş olmasına rağmen çalışmamızdan elde ettiğimiz başarı oranının Yang ve arkadaşlarından daha yüksek çıkmasının nedeninin, daha geniş bir anatomik alanın incelenmesinin yanında daha fazla alanda etiketleme yapılarak çeşitliliğin artırılmasından kaynaklandığını düşünmekteyiz.

Veri setinde 226 adet panoramik radyografinin bulunduğu bir çalışmada, sadece mandibulada ve radyolusent görüntü veren lezyonların nesne tespiti ve segmentasyonunda derin öğrenme mimarilerinden YOLOv8'in başarısı araştırılmış, YOLOv8 l alt modeli kullanılarak nesne tespiti ve segmentasyonda veri artırma yapılmadan elde edilen sonuçlarda mAP50 değeri sırasıyla %75.8 ve %75.1 olarak elde edilmiştir. Aynı çalışmada veri artırılarak yapılan deneyler sonucunda ise bu başarı oranı nesne tespiti ve segmentasyon işlemi için sırasıyla %97.5 ve %96.6 olarak bulunmuştur (Rašić ve ark., 2023). Çalışmamızda da nesne tespiti ve segmentasyon problemlerinde YOLOv8 mimarisi kullanılmış ve veri sayısı artırılmadan elde edilen sonuçlara göre sadece radyolusent lezyonlar için nesne tespitindeki başarı oranı YOLOv8 l modeli ile %80.7 iken segmentasyon yaklaşımında aynı modelle başarı oranı %74.1 olarak bulunmuştur. Yine çalışmamızda en yüksek başarı oranı ise nesne tespitinde YOLOv8 l modeli ile %80, segmentasyonda ise YOLOv8 m modeli ile %78.4 olarak elde edilmiştir. Çalışmamızdan elde ettiğimiz başarı oranlarının bu çalışmaya kıyasla daha yüksek çıkmasının nedenini hem her iki çenenin hem de daha fazla sayıda veri setinin çalışmaya dahil edilmiş olmasından kaynaklandığını düşünmekteyiz. Literatürde panoramik radyografiler üzerinde nesne tespiti ve segmentasyon yaklaşımı için YOLOv8 mimarisinin kullanıldığı başka bir çalışmaya rastlanmadı.

Literatür incelendiğinde YZ çalışmalarının çoğu panoramik radyografiler üzerinde yapılmakla birlikte panoramik radyografilerden oluşan veri seti ile maksillofasial bölgeye ait lezyon tespiti için yapılan çalışma sayısı oldukça sınırlıdır. Lezyonlarla ilgili yapılan YZ çalışmalarının çoğu da YZ'nin sınıflandırma ve segmentasyon problemlerindeki başarısını araştırmaya yöneliktir. Yapılan bir çalışmada, panoramik radyografiler üzerinde çenelerdeki kist ve osteonekrozun sınıflandırması yapılmış sinir ağlarının en iyi performansı %85 doğrulukla ölçülmüştür (Mikulka ve ark., 2013). Başka bir çalışmada da 133 adet panoramik görüntüden oluşan veri setinde SVM kullanılarak kist ve tümör sınıflandırması yapılmış ve sınıflandırma performansında %87.18 doğruluk elde edilmiştir (Nurtanio ve ark., 2013). Arij ve ark. (2019) yaptığı bir çalışmada derin öğrenme yöntemlerini kullanarak panoramik radyografiler üzerinde sadece alt çenede yer alan ve nispeten daha sık görülen 5 farklı radyolusent lezyonun tespit ve sınıflandırmasını yapmış ve bu amaçla 210 adet panoramik görüntüden oluşan veri seti kullanmışlardır. Sonuçta nesne tespitindeki en iyi başarı oranı %88 ve sınıflandırmadaki başarı oranını da %82 olarak dentigeröz kistler için elde edilmiştir. Çalışmamızda radyolusent görüntü veren lezyonlar çene ayrımı ve histolojik sınıflandırılması yapılmadan sadece radyolojik dansitesine göre YZ modelleriyle değerlendirilmiş ve sınıflandırmadaki başarı oranı %98.8 bulunurken, modellerin nesne tespitindeki başarı oranı da %80.7 olarak elde edilmiştir. Bununla birlikte çalışmamızda panoramik radyografilerin bütünü üzerinde lezyon var yok şeklinde probleme daha temel bir yaklaşım sergilenmiş ve 500 adet lezyondan 470 tanesini ayırt ederek %95.6 oranında doğruluk sergilediği tespit edilmiştir. Çalışmamıza göre nesne tespitinde ve sınıflandırmadaki başarı oranının Arji ve ark'dan daha yüksek oranda sonuçlanmasının nedenini hem her iki çenenin hem de daha fazla sayıda veri setinin çalışmaya dahil edilmiş olmasından kaynaklandığını düşünmekteyiz.

Lezyonların tespiti ve sınıflandırılmasındaki başarısızlık genellikle küçük boyutlarda ve sınırları net olmayan, zayıf radyolojik görüntü veren lezyonlar sebebiyle oluşmaktadır. Özellikle belirsiz erken dönem patolojileri ve çevre anatomik yapıların süperpozisyonu sonucu tecrübeli hekimlerin bile teşhisinde zorlandığı lezyonlar, kullanılan YZ algoritmaları için zorlayıcı unsur olabilmektedir. Bu nedenle, bu tez çalışmasında hem panoramik görüntülerin bütünü üzerinde hem de görüntünün bütününden lezyonlu alan kırılarak lezyon sınıflaması yapılmıştır ve iki farklı yaklaşım arasında anlamlı derecede fark bulunmuştur. Panoramik radyografilerin bütünü üzerinde radyopak ve radyolusent lezyon sınıflandırmasında en yüksek başarı oranı VGG16 modeli ile %68.4 oranla, kırılmış görüntülerde ise bu oran daha da artarak %97.7'lere ulaştığı tespit edilmiştir. Modellerin daha yüksek başarı oranına ulaşabilmesi için panoramik radyografilerin bütünü üzerinde yapılan sınıflamada veri sayısının ve çeşitliliğinin artırılması gerektiğini söyleyebiliriz.

Literatür incelendiğinde, VGG16 modeli kullanılarak panoramik radyografilerin bütünü üzerinde lezyon sınıflamasına yönelik az sayıda çalışma mevcut olduğu görüldü. Çene tümörlerinin tanısına yönelik yapılan bir çalışmada, 250 adet ameloblastoma ve 250 adet odontotojenik keratokist içeren toplamda 500 adet panoramik görüntüden oluşan veri seti üzerinde lezyonların sınıflandırılması yapılmış, modelin çalışmadaki duyarlılık ve doğruluk oranları sırasıyla %81.8 ve %83 olarak elde edilmiştir (Poedjiastoeti & Suebnukarn, 2018). Panoramik radyografilerin bütünü üzerinde sınıflandırma yaptığımız ve bu literatürle ile kıyasladığımız çalışmamızda lezyonların çeşitliliği ile lokalizasyonlarının farklı olmasının ve lezyonların türüne göre veri sayısındaki uyumsuzluğun sonuçlarımızı etkilediğini gözlemlemekteyiz.

VGG 16 modeli kullanılarak yapılan bir başka sınıflama çalışmasında ise nazopalatin kanal kisti içeren 115 hastaya ait panoramik radyografi ve kist içermeyen 230

adet kontrol grubunun bulunduđu veri seti kullanılmış ve modelin sınıflamadaki doğruluk oranı %88 olarak elde edilmiştir. Aynı çalışmada LeNet modeli ile sınıflandırmadaki başarı oranı ise %85 bulunmuştur (İto ve ark., 2024). Panoramik radyografilerin bütünü üzerinde radyoopak ve radyolusent lezyonların sınıflamasının yapıldığı çalışmamızda ise VGG16 modeli ile elde edilen duyarlılık ve doğruluk oranları sırasıyla, %98.8 ve %68.4'tür. Aynı model ile lezyon alanlarını kırparak yaptığımız sınıflamada ise bu oranlar sırasıyla %93 ve %94 olarak elde edildi. Panoramik radyografilerin bütünü üzerinde sınıflandırma yaptığımız ve İto ve ark ile kıyasladığımız çalışmamızda lezyonların çeşitliliği ile lokalizasyonlarının farklı olmasının ve lezyonların türüne göre veri sayısındaki dengesizliğin sonuçlarımızı etkilediğini gözlemlemekteyiz.

Literatür incelendiğinde AlexNet modeli ile panoramik radyografiler üzerinde lezyon sınıflamasına ait çalışma örneğine rastlanmadı. Çalışmamızda lezyonların sınıflandırılmasında kullandığımız bu model ile elde edilen sonuçların, kullandığımız diğer modellerden VGG16 ve GoogleNet ile benzer oranlara sahip başarı sergilediğini tespit ettik.

Çalışmamızda aynı veri seti kullanılarak sınıflama problemine iki farklı yaklaşım sergilenmiş ve her iki yaklaşımda da AlexNet, VGG16 ve GoogleNet olmak üzere aynı CNN mimarilerinden yararlanıldı. Sınıflama problemlerinde genel başarı GoogleNet mimarisi ile elde edilirken, kırpılarak bakılan görüntülerde panoramik radyografinin bütününe göre modellerin sınıflamasında daha başarılı sonuçlar elde edildiği görüldü. Literatürde iki farklı yaklaşımı birlikte kıyaslayan herhangi bir çalışma olmamakla birlikte çalışmamızın neticesinde panoramik radyografilerin bütünü üzerinde yapılan sınıflamadaki başarının daha az olmasını, çevre anatomik yapıların karmaşıklığına bağlı olarak incelenen alanın büyüklüğüne bağlamaktayız.

Çalışmamızda aynı veri seti kullanılarak sınıflama problemine üç sınıflı ve dört sınıflı farklı yaklaşımlar da sergilendi ve her iki yaklaşımda da AlexNet, VGG16 ve GoogleNet olmak üzere aynı CNN mimarilerinden yararlanıldı. Sınıflama problemlerinde genel başarı her iki yaklaşımda da GoogleNet mimarisi ile elde edildi. Literatürde iki farklı yaklaşımı da ayrı ayrı kıyaslayan herhangi bir çalışma olmamakla birlikte çalışmamızın neticesinde panoramik radyografilerin bütünü üzerinde yapılan sınıflamadaki başarının düşük olmasını, çevre anatomik yapıların karmaşıklığına bağlı olarak incelenen alanın büyüklüğüne bağlamaktayız.

Derin öğrenme yöntemleri ile sadece maksillar bölgedeki kist benzeri lezyonların tespitine yönelik çalışmalar da yapılmıştır. Yapılan bir çalışmada, 412 adet panoramik radyografiden oluşan veri setinde sadece radyolusent görünüm veren lezyonlar %75-77 oranında tespit edilmiştir. Bu çalışmadan elde edilen sonuçların mandibuladaki radyolusent lezyonların tespitine göre daha düşük başarı sergilemesinin nedeni olarak, maksilladaki lezyonlar ve çevre yapılar arasındaki düşük kontrast ve lezyonların maksiller sinüs, nazal kavite, sert damak, inferior konka ve diğer anatomik yapılar tarafından süperpoze olması ve dolayısıyla daha zor okunabilmesinden kaynaklandığı öne sürülmüştür (Watanabe ve ark., 2021). Ayrıca, bazı görüntülerde maksiller sinüsün alveoler kret seviyesine kadar uzanması sonucu YZ'nin yanlışlıkla bir lezyon olarak tespit edebileceği bildirilmiştir (Ohashi ve ark., 2016). Bu çalışmaların sonuçlarıyla uyumlu olarak bizim çalışmamızda da panoramik görüntülerdeki anatomik yapıların neden olduğu süperpozisyonların lezyon tespitinin başarısını etkileyebildiğini gözlemledik. Üst çenede özellikle hekimlerin de ayırt etmekte zorlandığı septa formasyonu içeren maksiller sinüs, nasal fossa ve hava yolu arkalarının sergiledikleri düşük dansite nedeniyle radyolusent lezyonların tespitini, yine sert damak hattı, mandibula üzerine süperpoze olan hiyoid kemik, vertebralar ve ghost imajlar ise yoğun dansite sergileyerek radyoopak

lezyonların tespitini zorlaştırmıştır. Bu da sadece radyolusent lezyonların değil radyoopak lezyonların da panoramik radyografilerde tespitindeki başarıyı etkilemektedir. Bu nedenle çalışmamızda maksilla ve mandibula ayrımı yapılmadan radyolusent lezyonların tespitinde %80, radyoopak lezyonların tespitinde %70 olmak üzere ortalama %75 lik başarı elde edilmiştir.

GoogleNet mimarisi kullanılarak yapılan bir çalışmada, idiyopatik osteoskleroz mevcut olan 493 adet panoramik radyografi üzerinde GoogleNet Inception v2 modeli kullanılarak lezyonun tespit edilmesi amaçlanmış ve duyarlılık, kesinlik ve F1 puan değerleri sırasıyla 0.88, 0.83, 0.86 olarak elde edilmiştir. İdiyopatik osteoskleroz dışındaki diğer radyoopak lezyonlar çalışma dışı tutulmuştur (Yesiltepe ve ark., 2022). Yaptığımız çalışmada ise maksillofasial bölgede görülen tüm radyoopak lezyonlar, sınıflandırma, nesne tespiti ve segmentasyon problemlerine dahil edildi ve bu çalışmayla benzer olarak sınıflandırmada GoogleNet mimarisinden yararlanıldı. GoogleNet modelinin, panoramik radyografinin bütünü üzerinde radyoopak-radyolusent lezyon sınıflamasındaki oransal performansının %82 duyarlılık, %70.5 kesinlik ve %75.8 F1 puanı sergilediği belirlendi. Yesiltepe ve ark. ile kıyaslandığında yakın sonuçlar elde ettiğimiz çalışmamızda, kullandığımız veri setini oluşturan lezyonların histopatolojik olarak tek çeşit ve tek dansiteye sahip lezyonlar olmaması ve lezyonların türüne göre veri sayısında da dengeli olunmamasına rağmen başarının modelin performansına bağlı olduğunu düşünmekteyiz.

Literatür incelendiğinde maksillofasial bölgede görülen çeşitli lezyonların YZ modelleri ile sınıflandırılması, tespit edilmesi ve segmentasyonu için çok sayıda radyografik görüntülerden yararlanılmıştır. Bu çalışmalarda panoramik radyografilerden oluşan veri setleri ile patolojik oluşumlar tespit edilebilirken, komşu anatomik yapıların süperpozisyonları, lezyonun 3 boyutta incelenememesi gibi nedenlerle bazı araştırmacılar

çalışmalarını CBCT görüntüleri üzerinde de yürütmüşlerdir. Lee ve ark. (2020) yaptıkları bir çalışmada, veri seti olarak hem panoramik hem CBCT görüntülerini kullanmış ve GoogleNet Inception v3 modelinden türetilen önceden eğitilmiş derin bir CNN mimarisi ile odontojenik keratokist, dentigeröz kist ve periapikal kistlerin teşhis ve tespitini değerlendirmişlerdir. Araştırmalarının neticesinde elde ettikleri modelin doğruluğu CBCT görüntülerinde %91.4 iken, panoramik görüntülerde %84.6 olarak bulunmuştur. CBCT'deki bu yüksek başarı oranının nedenini, süperpozisyona mahal vermeden farklı düzlemlerde kesitsel inceleme avantajı sağlayan CBCT yönteminin doğasına bağlamışlardır.

Yapılan bir çalışmada klinik, radyolojik ve histopatolojik olarak belirlenmiş iki ayrı lezyona ait ve 50 hastadan oluşan CBCT görüntüleri üzerinde SVM sınıflayıcısı ile lezyonların yüksek doğrulukla sınıflandırılabilirliği gösterilmiştir (Yılmaz ve ark., 2017). Abdolali ve ark. yaptıkları çalışmada, kistik lezyon bulunduran 97 hastaya ait CBCT görüntülerinden oluşan veri seti kullanarak, lezyonların segmentasyonunda asimetri analizine dayanan bir yöntem geliştirmişlerdir. Çalışmalarının neticesinde kistlerin çeşitli konumlarda ve boyutlarda olması, çevre dokularla benzer yoğunluklarda görüntü sergilemesi gibi durumlardan dolayı, geleneksel segmentasyon algoritmalarının çok sayıda hatalı pozitif piksel üretebileceğini ve zayıf bölütleme sergileyebileceğini bildirmişlerdir (Abdolali ve ark., 2016). Çalışmamızda ise sadece kistik görüntüler değil dansiteleri farklı çok sayıda lezyonun segmentasyonu panoramik radyografiler üzerinde yapılmış, görüntülerdeki piksel sayısının fazla olması ve bunun da sinir ağı modellerinin doğru şekilde tasarlanmasını zorlaştırmış olmasına rağmen az sayıda veri ile %72.1 oranında başarı elde edilmiştir.

Maksillofasial bölgedeki lezyonların üç boyutlu hacimsel hesaplamasının lezyonların değerlendirilmesi sürecinde birçok avantajı vardır (Krennmair & Lenglinger,

1995). Doğru şekilde segmentasyon, lezyonların lokalizasyonunun ve boyutlarının doğru tahmin edilmesine imkan sağlar (Essig ve ark., 2011). Rana ve ark. (2015) yaptıkları bir çalışmada, histolojik olarak tanımlanmış mandibular keratistik odontojenik tümörlerin segmentasyonunda, farklı segmentasyon yöntemlerini karşılaştırmış ve 38 hastaya ait 3 boyutlu görüntülerden oluşan veri setlerini kullandılar. Manuel ve eşik tabanlı segmentasyon ile yeni sunulan otomatik segmentasyon yöntemini (smartbrush) kullanılabilirlik, zaman ve doğruluk açısından karşılaştırarak, smartbrush sisteminin hızlı ve güvenilir sonuçlar verdiğini bildirdiler. YZ modellerinin lezyon içeren bölgenin hangi piksellerde radyopak hangi piksellerde radyolusent alan içerdiğini araştırdığımız çalışmamızda, segmentasyon probleminde de gerçek zamanlı tespit yapabilen YOLO mimarisinden yararlanarak, kutulama (bounding box) ile lezyon tespitinde %71.5 ve piksel düzeyinde sınıflamada ise %72.1 başarı elde ettik. Elde edilen bu sonuçlara göre YZ yöntemleriyle yapılan segmentasyon işlemleri cerrahi işlem öncesi lezyonlu bölgenin hacimsel olarak tespit edilmesine imkân tanıyarak bu alanda yapılacak yeni çalışmalara ışık tutacağını düşünmekteyiz.

Yapay zeka yöntemleri kullanılarak patolojik oluşumların tespitine yönelik az sayıda çalışma mevcuttur (Schwendicke ve ark., 2019). Bunun nedeni ise genellikle patolojik oluşumlara ait verilerdeki dengesizliktir. Evrimsel sınır ağlarının ağırlıklandırma parametrelerini en iyi düzeye çıkarma ihtiyacı göz önüne alındığında YZ algoritmaları için daha fazla veri gerekmektedir. Çünkü veri dengesizliği durumlarında doğruluk oranları yanıltıcı olabilmektedir (Krois ve ark., 2019).

Gulshan ve ark. yaptıkları bir çalışmada, evrimsel sınır ağları ile en iyi performansa ulaşabilmek için çeşitliliği artırabilecek onbinlerce vakanın yer aldığı geniş bir veri kümesinin olması gerektiğini savundular. Bu açıdan çalışmalarında modeli geliştirmek üzere 60.000 görüntüden oluşan bir veri seti kullandılar (Gulshan ve ark.,

2016). Cha ve ark. yaptıkları bir çalışmada 10.544 adet otoendoskopik görüntüden oluşan geniş bir veri seti kullanarak patolojik oluşumları teşhis etmede %93.73'lük başarı oranına ulaştılar. Yaptıkları çalışma neticesinde mevcut modeldeki yüksek doğruluk oranını kullanılan yüksek sayıdaki veri setine bağlamışlardır (Cha ve ark., 2019).

Maksillofasial bölgede yaygın olarak görülen lezyonların başında radiküler kist ve sonrasında dentigeröz kistler gelirken diğer patolojik oluşumların görülme sıklıkları daha az olup, bu dengesiz dağılım çalışma için elde edilecek veri setinin başarısında engel teşkil etmektedir (Açıkgöz ve ark., 2012). Çalışmamızda da arşiv materyallerinden elde edilen panoramik radyografilerde radyoopak ve radyolusent görüntü veren lezyonların dağılımı eşit değildir. Lenf nodu kalsifikasyonları, sialolit gibi radyoopak görüntü verip nadir olarak görülen lezyonlar da çalışmaya dahil edilmiştir. Bu tür lezyonların sayısı az olup lokalizasyon olarak da çeşitli varyasyonlar sergilemektedirler. Bu nedenle çalışmamızın sonuçlarına göre, YZ modellerinin radyolusent lezyonları sınıflandırma, tespit etme ve segmentasyon problemlerinde radyoopaklara lezyonlara göre daha yüksek başarı elde ettiği söylenebilir. Yine de bu çalışmanın sınırlamaları dahilinde, sınırlı sayıda etiketli panoramik görüntü üzerinde eğitilmiş YZ modelleri ile lezyonların sınıflandırılmasında, tespitinde ve segmentasyonunda iyi bir başarı elde ettiğimizi düşünmekteyiz.

YZ algoritmalarının tanı ve teşhisteki performanslarının elde edilmiş yüksek doğruluklu sonuçlarla uzman hekimlere eşdeğer olduğunu gösteren literatürde bazı çalışmalar vardır (J. H. Lee ve ark., 2020; Poedjiastoeti & Suebnukarn, 2018; Tuzoff ve ark., 2019). Fakat bu çalışmalar genellikle hekimlerin de ayırt etmekte zorlanmadıkları belirli tip lezyonların tespiti veya diş numaralandırma gibi lezyon dışında kalan diğer problemleri içeren çalışmalardır. Bu tez çalışmasında ise hekimlerin teşhis etmekte zorlanabileceği, belirli ve standart konumda bulunmayan geniş yelpazedeki çok sayıda

lezyona yönelik bir araştırma yapılmış ve maksilloofasial bölgede radyopak ve radyolusent görüntü veren lezyonların sınıflandırılmasında YZ algoritmaları en az %68, lezyon tespitinde %75 ve görüntü bölütlemeye de %72 oranında bir başarı elde edilmiştir. YZ çalışmalarıyla performans başarısının gelecekte %99'a ulaşacağı çalışmalarla, klinik pratiğinde maksillofasiyal bölgedeki lezyonların ve özelliklerinin otomatik olarak tespit ve sınıflandırılmasının mümkün olabileceğini düşünmekteyiz.

Bu tez çalışmasının sınırlamaları dahilinde hasta veya çekim kaynaklı artefakt bulunan (metal artefaktı, hareket artefaktı ve distorsiyonlar gibi), malign, agresif yapıda, trabeküler kemik içerisine invaze olmuş ve sınırları belirlenemeyen lezyonlara sahip olan, incelenecek alanın bütünüyle görüntülenmesine imkân vermeyecek kraniyo fasial deformiteye sahip hastalara ait panoramik radyografiler veri setine dahil edilmemiştir. Yani çalışmamız, bu sınırlandırmalar ve arşiv kayıtlarımızın yetersizliğinden ötürü olabilecek maksimum veri seti ile yürütülmüştür. Gelecekte sınırlandırmaların daha dar tutulduğu ve geniş bir popülasyon üzerinde yapılacak yeni çalışmalarda, keşfedilecek daha verimli YZ algoritmaları ile çok daha başarılı sonuçlar elde edileceğini düşünmekteyiz.

Çalışmamızdaki veri setini oluşturan görüntüler aynı panoramik cihaz ve birbirine yakın parametrelerle çekilen görüntü verilerinden oluşmaktadır. Cihazların teknik özellikleri ve çekim parametreleri, görüntüyü şekillendiren yazılım programları ve dicom alt yapılar, hatta görüntülerin izlendiği monitörlerin çözünürlükleri arasındaki farklılıkların, radyopak ve radyolusent bir lezyonun dansitesini etkileyerek lezyon değerlendirmesinde çeşitliliğe neden olabileceği kabul edilen bir gerçektir. Bu açıdan yapılacak yeni çalışmalarda kullanılacak farklı görüntülerle çeşitlilik artırılarak daha başarılı sonuçların elde edilebileceğini düşünmekteyiz.

Bu tez çalışmasında, maksillofasial bölgede radyopak ve radyolusent görüntü veren lezyonların incelenmesinde panoramik radyografilerden oluşan verilerle eğitilmiş YZ algoritmalarının iyi performans sergilediklerini söylebiliriz. İntraoral radyografi teknikleri ve CBCT, MR, USG gibi ileri görüntüleme teknikleri kullanılarak oluşturulan veri setleriyle, gelecekte ve benzer konularda yapılacak YZ çalışmalarında başarı oranları kıyaslanabilir.



6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, panoramik radyografiler üzerinde maksillofasiyal bölgede lezyon varlığı, görüntü veren lezyonların dansitelerine göre ayrımı derin öğrenme algoritmalarından AlexNet, VGG16 ve GoogleNet ile değerlendirilip bu modellerin sınıflandırmadaki başarılarının belirlenmesi amaçlandı. Radyopak ve radyolusent lezyonların tespiti ve segmentasyonun da ise YOLOv8 modelinin başarısı araştırıldı. Çalışmanın sonuçlarına göre;

- Panoramik radyografilerin bütünü üzerinde lezyon var-yok şeklindeki iki sınıflı sınıflandırma probleminde YZ modellerinin performanslarına bakıldığında farklı modeller kullanılarak doğruluk değerinin en yüksek %95.6 ve en düşük %64.7 oranında olduğu belirlendi. Bu sınıflamadaki en yüksek başarıyı GoogleNet sergilerken en düşük başarıyı VGG 16 gösterdi.
- Tüm PR'ler üzerinde radyopak-radyolusent lezyon sınıflamasının yapıldığı iki sınıflı başka bir problemde ise farklı modeller kullanılarak doğruluk değerinin en yüksek %68.4 en düşük %63.7 oranında olduğu görüldü. Önceki problemin aksine bu sınıflamada ise en yüksek başarı VGG 16 ile en düşük başarı ise AlexNet ile elde edildi. Aynı problemin üç sınıflı sınıflandırmasında radyopak lezyonlar, radyolusent lezyonlar ve radyopak-radyolusent lezyonların beraber bulunduğu görüntülerde modellerin başarısı %61.6 doğruluk oranı sergiledi. Radyopak lezyonlar, radyolusent lezyonlar, radyopak-radyolusent lezyonlar ve lezyon yok seçeneklerinin bulunduğu dört sınıflı sınıflandırmada ise %75.7 doğruluk elde edildi. Üç sınıflı ve dört sınıflı sınıflandırma probleminde de en yüksek başarıyı GoogleNet modeli sergiledi.
- Lezyonlu bölgenin kırpılarak bakıldığı sınıflandırma yaklaşımında, önceki sınıflandırmaya göre daha yüksek sonuçlar elde edilmiş olup, kullanılan derin

öğrenme algoritmalarından elde edilen sonuçlara göre GoogleNet ve AlexNet modelleri ile %96.5 doğruluk ve fusion sonucunda ise %97.7 oranı ile modellerin tek tek performansına göre daha yüksek başarı elde edildi.

- Lezyonların konumlarının tespit edilmesinde kullanılan derin öğrenme algoritmalarından biri olan YOLOv8 l'in tahmin başarısı radyolusent lezyonların tespitinde %80.7, radyoopak lezyonların tespitinde %70.2 ve tüm sınıflamada %75.4 oranında bulundu.
- Segmentasyon yaklaşımında kutulama ile nesnenin tespit edilmesinde ve piksel düzeyinde sınıflamanın yapılmasında en iyi model YOLOv8 m olarak belirlenmiştir. Kutu içerisine alarak nesneleri tespit etmede genel sınıflamada %71.5 ve piksel düzeyinde lezyonları sınıflamada %72.1 oranında başarı sergilenmiştir.
- YZ algortimalarının panoramik radyografiler üzerinde lezyonları belirleyebilmesi ve dansitelerine göre sınıflandırma yapabilmesindeki sonuçları umut vericidir. Çalışmada eğitilen AlexNet, VGG16, GoogleNet ve YOLOv8 modellerinden özellikle ikili sınıflamada başarı oranı %97, lezyon tespitinde %75 ve segmentasyon problemlerinde %72'lere ulaşılabilir.
- YZ modellerinin üç sınıflı sınıflandırmasındaki başarı oranı diğer sınıflandırma sonuçlarına göre en düşük oranda GoogleNet ile elde edilmiştir.
- Radyolusent lezyonların tespitindeki başarı oranı radyoopak lezyonlara göre daha fazla bulundu.
- Çalışmamızda maksillofasiyal bölgede görüntü veren lezyonların varlığını ve dansitelerine göre hangi sınıfa ait olduğunun, lezyonların radyoopak ve radyolusent ayrımının panoramik radyograflarda YZ modelleri ile başarılı bir şekilde tespit edilebildiğini söyleyebiliriz. Bu nedenle YZ destekli sistemlerin cerrahi işlemler öncesinde klinik pratiğine olumlu yönde katkı sağlayabileceğini düşünmekteyiz.

Ayrıca, daha geniş veri setleri ve farklı merkezlerdeki cihaz ve ekipmanlarla elde edilen verilerle çeşitlilik artırılarak daha farklı sonuçlar elde edilebileceğini düşünmekteyiz.

- Bu tez çalışması panoramik görüntülerden oluşan veriler ile gerçekleştirilen bağımsız bir derin öğrenme uygulamasını kapsamakta, YZ modellerini hastane sistemlerine entegre ederek son teknoloji derin öğrenme yaklaşımlarının klinik alanda etkili bir şekilde uygulayabilme ve lezyon teşhisinde diş hekimlerine yardımcı olabilme amacını taşımaktadır.



KAYNAKLAR

- Abdolali, F., Zoroofi, R. A., Otake, Y., & Sato, Y. (2016). Automatic segmentation of maxillofacial cysts in cone beam CT images. *Computers in biology and medicine*, 72, 108-119.
- Abraham, A. (2005). Artificial neural networks. *Handbook of measuring system design*.
- Açıkgöz, A. (2015). Çene Kemiklerinde İzlenen Malign Lezyonlar. *Turkiye Klinikleri J Oral Maxillofac Radiol-Special Topics*, 1(2), 1-9.
- Açıkgöz, A., Uzun-Bulut, E., Özden, B., & Gündüz, K. (2012). Prevalence and distribution of odontogenic and nonodontogenic cysts in a Turkish population. *Medicina oral, patologia oral y cirugia bucal*, 17(1), e108.
- Adisa, A. O., Adeyemi, B. F., Oluwasola, A. O., Kolude, B., Akang, E. E., & Lawoyin, J. O. (2011). Clinico-pathological profile of head and neck malignancies at University College Hospital, Ibadan, Nigeria. *Head & face medicine*, 7, 1-9.
- Ariji, Y., Fukuda, M., Kise, Y., Nozawa, M., Yanashita, Y., Fujita, H., Katsumata, A., & Ariji, E. (2019). Contrast-enhanced computed tomography image assessment of cervical lymph node metastasis in patients with oral cancer by using a deep learning system of artificial intelligence. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 127(5), 458-463.
- Ariji, Y., Yanashita, Y., Kutsuna, S., Muramatsu, C., Fukuda, M., Kise, Y., Nozawa, M., Kuwada, C., Fujita, H., & Katsumata, A. (2019). Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 128(4), 424-430.
- Askar, H., Krois, J., Rohrer, C., Mertens, S., Elhennawy, K., Ottolenghi, L., Mazur, M., Paris, S., & Schwendicke, F. (2021). Detecting white spot lesions on dental

- photography using deep learning: A pilot study. *Journal of Dentistry*, 107, 103615.
- Avril, L., Lombardi, T., Ailianou, A., Burkhardt, K., Varoquaux, A., Scolozzi, P., & Becker, M. (2014). Radiolucent lesions of the mandible: a pattern-based approach to diagnosis. *Insights into imaging*, 5, 85-101.
- Azimi, S., Tofangchiha, M., Shapoori, M., & Rafieian, N. (2016). Iranian Dental Students' Level of Knowledge Regarding the Interpretation of Radiographic Images of Oral Lesions: Is the Standard Training Sufficient? *Journal of Dentomaxillofacial*, 5(2), 1-5.
- BAŞARAN, K. (2024). *Diabetes mellituslu hastalarda submandibular tükürük bezinin cbct sialografisi ile incelenmesi* (Publication Number 844332) [Doktora tezi, Atatürk Üniversitesi].
- Baxt, W. G. (1991). Use of an artificial neural network for the diagnosis of myocardial infarction. *Annals of internal medicine*, 115(11), 843-848.
- Bayrakdar, İ. Ş. (2015). Çenelerde görülen intraosseöz lezyonların dental volumetrik tomografi, ultrasonografi ve histopatolojik bulgularının değerlendirilmesi.
- Bilgir, E., Bayrakdar, İ. Ş., Çelik, Ö., Orhan, K., Akkoca, F., Sağlam, H., Odabaş, A., Aslan, A. F., Ozcetin, C., & Kılı, M. (2021). An artificial intelligence approach to automatic tooth detection and numbering in panoramic radiographs. *BMC medical imaging*, 21, 1-9.
- Bishop, C. M. (1995). *Neural networks for pattern recognition*. Oxford university press.
- Bruellmann, D., Tjaden, H., Schwanecke, U., & Barth, P. (2013). An optimized video system for augmented reality in endodontics: a feasibility study. *Clinical oral investigations*, 17, 441-448.

- Casalegno, F., Newton, T., Daher, R., Abdelaziz, M., Lodi-Rizzini, A., Schürmann, F., Krejci, I., & Markram, H. (2019). Caries detection with near-infrared transillumination using deep learning. *Journal of dental research*, 98(11), 1227-1233.
- Cha, D., Pae, C., Seong, S.-B., Choi, J. Y., & Park, H.-J. (2019). Automated diagnosis of ear disease using ensemble deep learning with a big otoendoscopy image database. *EBioMedicine*, 45, 606-614.
- Chabi Adjobo, E., Sanda Mahama, A. T., Gouton, P., & Tossa, J. (2023). Automatic localization of five relevant Dermoscopic structures based on YOLOv8 for diagnosis improvement. *Journal of Imaging*, 9(7), 148.
- Chen, X.-W., & Lin, X. (2014). Big data deep learning: challenges and perspectives. *IEEE access*, 2, 514-525.
- Choi, H.-I., Jung, S.-K., Baek, S.-H., Lim, W. H., Ahn, S.-J., Yang, I.-H., & Kim, T.-W. (2019). Artificial intelligent model with neural network machine learning for the diagnosis of orthognathic surgery. *Journal of Craniofacial Surgery*, 30(7), 1986-1989.
- Cotti, E., Campisi, G., Garau, V., & Puddu, G. (2002). A new technique for the study of periapical bone lesions: ultrasound real time imaging. *International Endodontic Journal*, 35(2), 148-152.
- Çağlayan, F. (2016). Tükürük bezi patolojilerinin teşhisinde ultrasonun tani değeri. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi*, 25(3).
- Çakmak, S. (2022). Maksillofasiyal bölge klinik anatomisi. In Y. M (Ed.), *Maksillofasiyal Cerrahi* (pp. 4-11). Türkiye Klinikleri.
- Dahlin, D. C., & Unni, K. K. (1986). Bone tumors: general aspects and data on 8,547 cases.

- Davies, A. M., & Pettersson, H. (2002). *The WHO manual of diagnostic imaging: radiographic anatomy and interpretation of the musculoskeletal system* (Vol. 2). World Health Organization.
- Deo, R. C. (2015). Machine learning in medicine. *Circulation*, 132(20), 1920-1930.
- Devito, K. L., de Souza Barbosa, F., & Felipe Filho, W. N. (2008). An artificial multilayer perceptron neural network for diagnosis of proximal dental caries. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*, 106(6), 879-884.
- Di Martino, E., Nowak, B., Hassan, H. A., Hausmann, R., Adam, G., Buell, U., & Westhofen, M. (2000). Diagnosis and staging of head and neck cancer: a comparison of modern imaging modalities (positron emission tomography, computed tomography, color-coded duplex sonography) with panendoscopic and histopathologic findings. *Archives of Otolaryngology-Head & Neck Surgery*, 126(12), 1457-1461.
- Dib, L. L., Curi, M. M., Chammas, M. C., Pinto, D. S., & Torloni, H. (1996). Ultrasonography evaluation of bone lesions of the jaw. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*, 82(3), 351-357.
- Doğan, F., & Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- Drage, N., & Rout, J. (2010). Diagnostic imaging. *Three-Dimensional Imaging for Orthodontics and Maxillofacial Surgery*, 29-72.
- Du, X., Chen, Y., Zhao, J., & Xi, Y. (2018). A convolutional neural network based auto-positioning method for dental arch in rotational panoramic radiography. 2018 40th

- annual international conference of the IEEE engineering in medicine and biology society (EMBC),
- Dunfee, B. L., Sakai, O., Pistey, R., & Gohel, A. (2006). Radiologic and pathologic characteristics of benign and malignant lesions of the mandible. *Radiographics*, 26(6), 1751-1768.
- El-Naggar, A. K., Chan, J. K., Rubin Grandis, J., & Slootweg, P. J. (2017). WHO classification of head and neck tumours. (*No Title*).
- Ender, A., Mörmann, W. H., & Mehl, A. (2011). Efficiency of a mathematical model in generating CAD/CAM-partial crowns with natural tooth morphology. *Clinical oral investigations*, 15, 283-289.
- Ergezer, H., Dikmen, M., & Özdemir, E. (2003). Yapay sinir ağları ve tanıma sistemleri. *PiVOLKA*, 2(6), 14-17.
- Essig, H., Rana, M., Meyer, A., Eckardt, A. M., Kokemueller, H., von See, C., Lindhorst, D., Tavassol, F., Ruecker, M., & Gellrich, N.-C. (2011). Virtual 3D tumor marking-exact intraoperative coordinate mapping improve post-operative radiotherapy. *Radiation Oncology*, 6, 1-5.
- European Society of Radiology (ESR) communications@ myesr. org Neri Emanuele de Souza Nandita Brady Adrian Bayarri Angel Alberich Becker Christoph D. Coppola Francesca Visser Jacob. (2019). What the radiologist should know about artificial intelligence—an ESR white paper. *Insights into imaging*, 10(1), 44.
- Evirgen, Ş., & Kamburoğlu, K. (2016). Review on the applications of ultrasonography in dentomaxillofacial region. *World journal of radiology*, 8(1), 50.
- Farhadian, M., Shokouhi, P., & Torkzaban, P. (2020). A decision support system based on support vector machine for diagnosis of periodontal disease. *BMC Research Notes*, 13, 1-6.

- Farman, A. G. (2007). Panoramic radiology. *Getting the most out of Panoramic Radiographic Interpretation*. Berlin, Heidelberg: Springer-Verlag, 1-14.
- Firildak, K., & Talu, M. F. (2019). Evrişimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi. *Computer Science*, 4(2), 88-95.
- Flint, D. J., Paunovich, E., Moore, W. S., Wofford, D. T., & Hermes, C. B. (1998). A diagnostic comparison of panoramic and intraoral radiographs. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*, 85(6), 731-735.
- Goaz, P. W. (1987). Oral radiology. *Principles and interpretation*, 533-540.
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., Venugopalan, S., Widner, K., Madams, T., & Cuadros, J. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 316(22), 2402-2410.
- Gundappa, M., Ng, S., & Whaites, E. (2006). Comparison of ultrasound, digital and conventional radiography in differentiating periapical lesions. *Dentomaxillofacial Radiology*, 35(5), 326-333.
- Guo, J., Simon, J. H., Sedghizadeh, P., Soliman, O. N., Chapman, T., & Enciso, R. (2013). Evaluation of the reliability and accuracy of using cone-beam computed tomography for diagnosing periapical cysts from granulomas. *Journal of Endodontics*, 39(12), 1485-1490.
- Gurel, G. (2020). The Artificial Intelligence-Based 3D Smile Design: REBEL. *Esthetic Oral Rehabilitation with Veneers: A Guide to Treatment Preparation and Clinical Concepts*, 235-263.

- Gümüř, A. N. (2021). *Apikal lezyonların ultrasonografi ile muayenesinin etkinlięi* (Publication Number 698812) [Diř hekimlięi uzmanlık tezi, Kırıkkale Üniversitesi].
- Ha, E.-G., Jeon, K. J., Kim, Y. H., Kim, J.-Y., & Han, S.-S. (2021). Automatic detection of mesiodens on panoramic radiographs using artificial intelligence. *Scientific Reports*, 11(1), 23061.
- Handa, H., Naidu, G. S., Dara, B. G. B., Deshpande, A., & Raghavendra, R. (2014). Diverse imaging characteristics of a mandibular intraosseous vascular lesion. *Imaging science in dentistry*, 44(1), 67.
- Harorlı, A., Akgul, M., & Dagistan, S. (2006). Diř Hekimlięi Radyolojisi Kitabı. *Atatürk Üniversitesi Yayınları*, 80-150.
- Harorlı, A., Akgül, M., Yılmaz, B., Bilge, O., Dağıstan, S., Çakur, B., Çaęlayan, F., Miloęlu, Ö., & Sümbüllü, M. (2014). Ağız, Diř ve Çene Radyolojisi. 1. baskı İstanbul; Nobel Tıp Kitapevleri Tic. Ltd. Şti, 484-500.
- Hasbek, Z., İsmail, Ş., Yücel, B., & Babacan, N. A. (2013). Kemik metastazlarının tespitinde hangi görüntüleme yöntemini seçelim? kemik sintigrafisi, bt, 18f-fdg pet/bt veya mr? *Bozok Tıp Dergisi*, 3(3), 44-50.
- Haylaz, E., Şeker, Ç., Geduk, G., Murat, İ., & Gülşen, E. A. (2022). Retrospective Analysis of Oral and Maxillofacial Pathologies. *Journal of Contemporary Medicine*, 12(6), 877-883.
- Herrera, L. J., Pulgar, R., Santana, J., Cardona, J. C., Guillén, A., Rojas, I., & del Mar Pérez, M. (2010). Prediction of color change after tooth bleaching using fuzzy logic for Vita Classical shades identification. *Applied Optics*, 49(3), 422-429.
- Hiraiwa, T., Ariji, Y., Fukuda, M., Kise, Y., Nakata, K., Katsumata, A., Fujita, H., & Ariji, E. (2019). A deep-learning artificial intelligence system for assessment of

- root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofacial Radiology*, 48(3), 20180218.
- Hu, Z., Jiang, C., Sun, F., Zhang, Q., Ge, Y., Yang, Y., Liu, X., Zheng, H., & Liang, D. (2019). Artifact correction in low-dose dental CT imaging using Wasserstein generative adversarial networks. *Medical physics*, 46(4), 1686-1696.
- Iannucci, J., & Howerton, L. J. (2021). *Dental Radiography-E-Book: Dental Radiography-E-Book*. Elsevier Health Sciences.
- Ilhan, B., Lin, K., Guneri, P., & Wilder-Smith, P. (2020). Improving oral cancer outcomes with imaging and artificial intelligence. *Journal of dental research*, 99(3), 241-248.
- Isacsson, G., Isberg, A., Haverling, M., & Lundquist, P. G. (1984). Salivary calculi and chronic sialoadenitis of the submandibular gland: a radiographic and histologic study. *Oral surgery, oral medicine, oral pathology*, 58(5), 622-627.
- Ito, K., Hirahara, N., Muraoka, H., Sawada, E., Tokunaga, S., Komatsu, T., & Kaneda, T. (2024). Graphical user interface-based convolutional neural network models for detecting nasopalatine duct cysts using panoramic radiography. *Scientific Reports*, 14(1), 7699.
- Jadu, F., & Lam, E. (2013). A comparative study of the diagnostic capabilities of 2D plain radiograph and 3D cone beam CT sialography. *Dentomaxillofacial Radiology*, 42(1), 20110319-20110319.
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., Wang, Y., Dong, Q., Shen, H., & Wang, Y. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and vascular neurology*, 2(4).
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). YOLO by Ultralytics.

- Ju, R.-Y., & Cai, W. (2023). Fracture detection in pediatric wrist trauma X-ray images using YOLOv8 algorithm. *Scientific Reports*, 13(1), 20077.
- Kann, B. H., Aneja, S., Loganadane, G. V., Kelly, J. R., Smith, S. M., Decker, R. H., Yu, J. B., Park, H. S., Yarbrough, W. G., & Malhotra, A. (2018). Pretreatment identification of head and neck cancer nodal metastasis and extranodal extension using deep learning neural networks. *Scientific Reports*, 8(1), 14036.
- Karhade, D. S., Roach, J., Shrestha, P., Simancas-Pallares, M. A., Ginnis, J., Burk, Z. J., Ribeiro, A. A., Cho, H., Wu, D., & Divaris, K. (2021). An automated machine learning classifier for early childhood caries. *Pediatric dentistry*, 43(3), 191-197.
- Kaya, E., Gunec, H. G., Aydin, K. C., Urkmez, E. S., Duranay, R., & Ates, H. F. (2022). A deep learning approach to permanent tooth germ detection on pediatric panoramic radiographs. *Imaging science in dentistry*, 52(3), 275.
- Keskenler, M. F., & Keskenler, E. F. (2017). Bulanık mantığın tarihi gelişimi. *Takvim-i Vekayi*, 5(1), 1-10.
- Khanagar, S. B., Al-Ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., Sarode, S. C., & Bhandi, S. (2021). Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *Journal of dental sciences*, 16(1), 508-522.
- Kim, T. S., Obst, C., Zehaczek, S., & Geenen, C. (2008). Detection of bone loss with different X-ray techniques in periodontal patients. *Journal of periodontology*, 79(7), 1141-1149.
- Kise, Y., Ikeda, H., Fujii, T., Fukuda, M., Arijii, Y., Fujita, H., Katsumata, A., & Arijii, E. (2019). Preliminary study on the application of deep learning system to diagnosis of Sjögren's syndrome on CT images. *Dentomaxillofacial Radiology*, 48(6), 20190019.

- Koçer, B. (2012). Transfer öğrenmede yeni yaklaşımlar.
- Kositbowornchai, S., Plermkamon, S., & Tangkosol, T. (2013). Performance of an artificial neural network for vertical root fracture detection: an ex vivo study. *Dental traumatology*, 29(2), 151-155.
- Kök, H., Acilar, A. M., & İzgi, M. S. (2019). Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Progress in Orthodontics*, 20, 1-10.
- Krennmair, G., & Lenglinger, F. (1995). Imaging of mandibular cysts with a dental computed tomography software program. *International journal of oral and maxillofacial surgery*, 24(1), 48-52.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Krois, J., Graetz, C., Holtfreter, B., Brinkmann, P., Kocher, T., & Schwendicke, F. (2019). Evaluating modeling and validation strategies for tooth loss. *Journal of dental research*, 98(10), 1088-1095.
- Kunz, F., Stellzig-Eisenhauer, A., Zeman, F., & Boldt, J. (2020). Artificial intelligence in orthodontics: Evaluation of a fully automated cephalometric analysis using a customized convolutional neural network. *Journal of Orofacial Orthopedics/Fortschritte der Kieferorthopadie*, 81(1).
- Kurt Bayrakdar, S., Orhan, K., Bayrakdar, I. S., Bilgir, E., Ezhov, M., Gusarev, M., & Shumilov, E. (2021). A deep learning approach for dental implant planning in cone-beam computed tomography images. *BMC medical imaging*, 21(1), 86.
- Kuwana, R., Ariji, Y., Fukuda, M., Kise, Y., Nozawa, M., Kuwada, C., Muramatsu, C., Katsumata, A., Fujita, H., & Ariji, E. (2021). Performance of deep learning object

- detection technology in the detection and diagnosis of maxillary sinus lesions on panoramic radiographs. *Dentomaxillofacial Radiology*, 50(1), 20200171.
- Kwon, O., Yong, T.-H., Kang, S.-R., Kim, J.-E., Huh, K.-H., Heo, M.-S., Lee, S.-S., Choi, S.-C., & Yi, W.-J. (2020). Automatic diagnosis for cysts and tumors of both jaws on panoramic radiographs using a deep convolution neural network. *Dentomaxillofacial Radiology*, 49(8), 20200185.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lee, J.-G., Jun, S., Cho, Y.-W., Lee, H., Kim, G. B., Seo, J. B., & Kim, N. (2017). Deep learning in medical imaging: general overview. *Korean journal of radiology*, 18(4), 570.
- Lee, J.-H., Han, S.-S., Kim, Y. H., Lee, C., & Kim, I. (2020). Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 129(6), 635-642.
- Lee, J.-H., Kim, D.-H., Jeong, S.-N., & Choi, S.-H. (2018a). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of Dentistry*, 77, 106-111.
- Lee, J.-H., Kim, D.-h., Jeong, S.-N., & Choi, S.-H. (2018b). Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *Journal of periodontal & implant science*, 48(2), 114.
- Lee, J. H., Kim, D. H., & Jeong, S. N. (2020). Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. *Oral diseases*, 26(1), 152-158.

- Lee, K.-S., Jung, S.-K., Ryu, J.-J., Shin, S.-W., & Choi, J. (2020). Evaluation of transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs. *Journal of clinical medicine*, 9(2), 392.
- Lim, L. Z., Padilla, R. J., Reside, G. J., & Tyndall, D. A. (2018). Comparing panoramic radiographs and cone beam computed tomography: Impact on radiographic features and differential diagnoses. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 126(1), 63-71. e62.
- Lin, P.-L., Lai, Y.-H., & Huang, P.-W. (2010). An effective classification and numbering system for dental bitewing radiographs using teeth region and contour information. *Pattern recognition*, 43(4), 1380-1392.
- Lofthag-Hansen, S., Huuonen, S., Gröndahl, K., & Gröndahl, H.-G. (2007). Limited cone-beam CT and intraoral radiography for the diagnosis of periapical pathology. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*, 103(1), 114-119.
- Mascarenhas, S., & Agarwal, M. (2021). A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification. 2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON),
- Mathew, T. V. (2012). Genetic algorithm. *Report submitted at IIT Bombay*, 53.
- MERTOĞLU, D., Keser, G., PEKİNER, F. M. N., BAYRAKDAR, İ. Ş., ÇELİK, Ö., & Orhan, K. (2023). A Deep Learning Approach to Automatic Tooth Detection and Numbering in Panoramic Radiographs: An Artificial Intelligence Study. *Clinical and Experimental Health Sciences*, 13(4), 883-888.

- Miki, Y., Muramatsu, C., Hayashi, T., Zhou, X., Hara, T., Katsumata, A., & Fujita, H. (2017). Classification of teeth in cone-beam CT using deep convolutional neural network. *Computers in biology and medicine*, 80, 24-29.
- Mikulka, J., Gescheidtová, E., Kabrda, M., & Peřina, V. (2013). Classification of jaw bone cysts and necrosis via the processing of orthopantomograms. *Radioengineering*, 22(1), 115.
- Miloglu, O., Guller, M. T., & Tosun, Z. T. (2022). The Use of Artificial Intelligence in Dentistry Practices. *The Eurasian journal of medicine*, 54(Suppl1), 34-42.
- Mol, A. (2004). Imaging methods in periodontology. *Periodontology 2000*, 34(1), 34-48.
- Molander, B., Ahlqwist, M., Gröndahl, H., & Hollender, L. (1993). Comparison of panoramic and intraoral radiography for the diagnosis of caries and periapical pathology. *Dentomaxillofacial Radiology*, 22(1), 28-32.
- Moor, J. (2006). The Dartmouth College artificial intelligence conference: The next fifty years. *Ai Magazine*, 27(4), 87-87.
- Moutselos, K., Berdouses, E., Oulis, C., & Maglogiannis, I. (2019). Recognizing occlusal caries in dental intraoral images using deep learning. 2019 41st annual international conference of the IEEE engineering in medicine and biology society (EMBC),
- Mozzo, P., Procacci, C., Tacconi, A., Tinazzi Martini, P., & Bergamo Andreis, I. (1998). A new volumetric CT machine for dental imaging based on the cone-beam technique: preliminary results. *European radiology*, 8, 1558-1564.
- Murat, İ. (2019). Radyoopak ve radyolusent görüntü veren lezyonların konik ışınli bilgisayarlı tomografi ile retrospektif olarak incelenmesi. *Selcuk Dental Journal*, 6(4), 311-316.

- Murata, M., Arij, Y., Ohashi, Y., Kawai, T., Fukuda, M., Funakoshi, T., Kise, Y., Nozawa, M., Katsumata, A., & Fujita, H. (2019). Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral radiology*, 35, 301-307.
- Nam, Y., Kim, H. G., & Kho, H. S. (2018). Differential diagnosis of jaw pain using informatics technology. *Journal of Oral Rehabilitation*, 45(8), 581-588.
- Natkin, E., Oswald, R. J., & Carnes, L. I. (1984). The relationship of lesion size to diagnosis, incidence, and treatment of periapical cysts and granulomas. *Oral surgery, oral medicine, oral pathology*, 57(1), 82-94.
- Neyaz, Z., Gadodia, A., Gamanagatti, S., & Mukhopadhyay, S. (2008). Radiographical approach to jaw lesions. *Singapore Med J*, 49(2), 165-176.
- Nichols, J. A., Herbert Chan, H. W., & Baker, M. A. (2019). Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophysical reviews*, 11, 111-118.
- Nurtanio, I., Astuti, E. R., Purnama, I. K. E., Hariadi, M., & Purnomo, M. H. (2013). Classifying cyst and tumor lesion using support vector machine based on dental panoramic images texture features. *IAENG International Journal of Computer Science*, 40(1).
- Ohashi, Y., Arij, Y., Katsumata, A., Fujita, H., Nakayama, M., Fukuda, M., Nozawa, M., & Arij, E. (2016). Utilization of computer-aided detection system in diagnosing unilateral maxillary sinusitis on panoramic radiographs. *Dentomaxillofacial Radiology*, 45(3), 20150419.
- Orhan, K. (2012). Diş hekimliğinde konik ışınli komputerize tomografinin (KIKT) yeri ve önemi. *Yeditepe J Dent*, 3, 6-17.

- Orhan, K., Bayrakdar, I., Ezhov, M., Kravtsov, A., & Özyürek, T. (2020). Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *International Endodontic Journal*, 53(5), 680-689.
- Orhan, K., Misirli, M., Aksoy, S., Hincal, U. S. E., Ormeci, T., & Arslan, A. (2016). Morphometric analysis of the infraorbital foramen, canal and groove using cone beam CT: considerations for creating artificial organs. *The International Journal of Artificial Organs*, 39(1), 28-36.
- Ozcan, I. (2017). Diş Hekimliğinde Radyolojinin Esasları: Konvansiyonelden Dijitale.
- Özkan, İ., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Özkesici, M. Y., & Yilmaz, S. (2021). Oral ve Maksillofasiyal Radyoloji’de Yapay Zeka. *Sağlık Bilimleri Dergisi*, 30(3), 346-351.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ’ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Paatero, Y. (1961). Pantomography and orthopantomography. *Oral surgery, oral medicine, oral pathology*, 14(8), 947-953.
- Pauwels, R. (2021). A brief introduction to concepts and applications of artificial intelligence in dental imaging. *Oral radiology*, 37(1), 153-160.
- Pauwels, R., Beinsberger, J., Collaert, B., Theodorakou, C., Rogers, J., Walker, A., Cockmartin, L., Bosmans, H., Jacobs, R., & Bogaerts, R. (2012). Effective dose range for dental cone beam computed tomography scanners. *European journal of radiology*, 81(2), 267-271.
- PİRİM, A. G. H. (2006). Yapay zeka. *Yaşar Üniversitesi E-Dergisi*, 1(1), 81-93.
- Poedjiastoeti, W., & Suebnukarn, S. (2018). Application of convolutional neural network in the diagnosis of jaw tumors. *Healthcare informatics research*, 24(3), 236.

- Rana, A., Yauney, G., Wong, L. C., Gupta, O., Muftu, A., & Shah, P. (2017). Automated segmentation of gingival diseases from oral images. 2017 IEEE Healthcare Innovations and Point of Care Technologies (HI-POCT),
- Rana, M., Modrow, D., Keuchel, J., Chui, C., Rana, M., Wagner, M., & Gellrich, N.-C. (2015). Development and evaluation of an automatic tumor segmentation tool: a comparison between automatic, semi-automatic and manual segmentation of mandibular odontogenic cysts and tumors. *Journal of Cranio-Maxillofacial Surgery*, 43(3), 355-359.
- Rašić, M., Tropčić, M., Karlović, P., Gabrić, D., Subašić, M., & Knežević, P. (2023). Detection and Segmentation of Radiolucent Lesions in the Lower Jaw on Panoramic Radiographs Using Deep Neural Networks. *Medicina*, 59(12), 2138.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Regezi, J., Sceulba, J., & Jordon, R. (2003). *Clinical pathologic correlations*. Philadelphia.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Internal Representations by Error Propagation, Parallel Distributed Processing, Explorations in the Microstructure of Cognition, ed. DE Rumelhart and J. McClelland. Vol. 1. 1986. *Biometrika*, 71, 599-607.
- Saghiri, M. A., Asgar, K., Boukani, K., Lotfi, M., Aghili, H., Delvarani, A., Karamifar, K., Saghiri, A., Mehrvarzfar, P., & Garcia-Godoy, F. (2012). A new approach for locating the minor apical foramen using an artificial neural network. *International Endodontic Journal*, 45(3), 257-265.

- Sakamoto, H., Nakai, Y., Ohashi, Y., Okamura, T., & Ochi, H. (1997). Positron emission tomographic imaging of head and neck lesions. *European Archives of Oto-Rhino-Laryngology*, 254, S123-S126.
- Scarfe, W. C., & Farman, A. G. (2008). What is cone-beam CT and how does it work? *Dental Clinics of North America*, 52(4), 707-730.
- Schön, R., Düker, J., & Schmelzeisen, R. (2002). Ultrasonographic imaging of head and neck pathology. *Atlas of the oral and maxillofacial surgery clinics of North America*, 10(2), 213-241.
- Schwendicke, F., Golla, T., Dreher, M., & Krois, J. (2019). Convolutional neural networks for dental image diagnostics: A scoping review. *Journal of Dentistry*, 91, 103226.
- Sen, D., Chakrabarti, R., Chatterjee, S., Grewal, D., & Manrai, K. (2020). Artificial intelligence and the radiologist: the future in the Armed Forces Medical Services. *BMJ Mil Health*, 166(4), 254-256.
- Serhatlioğlu, S., & Hardalaç, F. (2009). Yapay zeka teknikleri ve radyolojiye uygulanması. *Fırat Tıp Dergisi*, 14(1), 1-6.
- Seth, V., Kamath, P., Venkatesh, M., & Prasad, R. (2011). Cone beam computed tomography: third eye in diagnosis and treatment planning. *Virtual Journal of Orthodontics*, 9(1).
- Shabbir, J., & Anwer, T. (2018). Artificial intelligence and its role in near future. *arXiv preprint arXiv:1804.01396*.
- Shahidi, S., Shakibafard, A., Zamiri, B., Mokhtare, M. R., Houshyar, M., & Mahdian, S. (2015). The feasibility of ultrasonography in defining the size of jaw osseous lesions. *Journal of Dentistry*, 16(4), 335.

- Simon, J. H., Enciso, R., Malfaz, J.-M., Roges, R., Bailey-Perry, M., & Patel, A. (2006). Differential diagnosis of large periapical lesions using cone-beam computed tomography measurements and biopsy. *Journal of endodontics*, 32(9), 833-837.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Slootweg, P. (2009). Lesions of the jaws. *Histopathology*, 54(4), 401-418.
- Soluk-Tekkesin, M., & Wright, J. M. (2022). The World Health Organization classification of odontogenic lesions: a summary of the changes of the 2022 (5th) edition. *Turkish Journal of Pathology*, 38(2), 168.
- Sumer, A., Danaci, M., Ozen Sandikçi, E., Sumer, M., & Celenk, P. (2009). Ultrasonography and Doppler ultrasonography in the evaluation of intraosseous lesions of the jaws. *Dentomaxillofacial Radiology*, 38(1), 23-27.
- Suzuki, K. (2017). Overview of deep learning in medical imaging. *Radiological physics and technology*, 10(3), 257-273.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Tao, Q., Biao, L., Bhatia, K. S., Qiao, B., Zheng, C.-q., & Chen, Z.-f. (2010). Three-dimensional CT angiography for the diagnosis and assessment of arteriovenous malformations in the oral and maxillofacial region. *Journal of Cranio-Maxillofacial Surgery*, 38(1), 32-37.
- Tektaş, M., Akbaş, A., & Topuz, V. (2002). Yapay zekâ tekniklerinin trafik kontrolünde kullanılması üzerine bir inceleme. *Uluslararası Trafik ve Yol Güvenliği Kongresi, Gazi Üniversitesi, Ankara*.

- Theodorou, D. J., Theodorou, S. J., & Sartoris, D. J. (2003). Primary non-odontogenic tumors of the jawbones: an overview of essential radiographic findings. *Clinical imaging*, 27(1), 59-70.
- Turing, A. M. (2009). *Computing machinery and intelligence*. Springer.
- Tuzoff, D. V., Tuzova, L. N., Bornstein, M. M., Krasnov, A. S., Kharchenko, M. A., Nikolenko, S. I., Sveshnikov, M. M., & Bednenko, G. B. (2019). Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology*, 48(4), 20180051.
- Underhill, T., Katz, J., Pope Jr, T., & Dunlap, C. (1992). Radiologic findings of diseases involving the maxilla and mandible. *AJR. American journal of roentgenology*, 159(2), 345-350.
- Van der Woude, H., Bloem, J., Verstraete, K., Taminiau, A., Nooy, M., & Hogendoorn, P. (1995). Osteosarcoma and Ewing's sarcoma after neoadjuvant chemotherapy: value of dynamic MR imaging in detecting viable tumor before surgery. *AJR. American journal of roentgenology*, 165(3), 593-598.
- Vandenberghe, B., Jacobs, R., & Bosmans, H. (2010). Modern dental imaging: a review of the current technology and clinical applications in dental practice. *European radiology*, 20, 2637-2655.
- Velemínská, J., Pilný, A., Čepěk, M., Kot'ová, M., & Kubelková, R. (2013). Dental age estimation and different predictive ability of various tooth types in the Czech population: data mining methods. *Anthropologischer Anzeiger*, 70(3).
- Vered, M., & Wright, J. M. (2022). Update from the 5th Edition of the World Health Organization classification of head and neck tumors: odontogenic and maxillofacial bone tumours. *Head and neck pathology*, 16(1), 63-75.

- Wang, L., Wang, D., Zhang, Y., Ma, L., Sun, Y., & Lv, P. (2014). An automatic robotic system for three-dimensional tooth crown preparation using a picosecond laser. *Lasers in surgery and medicine*, 46(7), 573-581.
- Watanabe, H., Ariji, Y., Fukuda, M., Kuwada, C., Kise, Y., Nozawa, M., Sugita, Y., & Ariji, E. (2021). Deep learning object detection of maxillary cyst-like lesions on panoramic radiographs: preliminary study. *Oral radiology*, 37, 487-493.
- White, S. (1989). Computer-aided differential diagnosis of oral radiographic lesions. *Dentomaxillofacial Radiology*, 18(2), 53-59.
- White, S. C., & Pharoah, M. J. (2014). *Oral radiology-E-Book: Principles and interpretation*. Elsevier Health Sciences.
- Wirtz, A., Mirashi, S. G., & Wesarg, S. (2018). Automatic teeth segmentation in panoramic X-ray images using a coupled shape model in combination with a neural network. Medical Image Computing and Computer Assisted Intervention–MICCAI 2018: 21st International Conference, Granada, Spain, September 16-20, 2018, Proceedings, Part IV 11,
- Wood, N. K., & Goaz, P. W. (1991). Differential diagnosis of oral lesions. (No Title).
- Xie, X., Wang, L., & Wang, A. (2010). Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *The Angle Orthodontist*, 80(2), 262-266.
- Yalçın, E. D., & Bozan, Ç. Oral ve maksillofasiyal patolojilerin incelenmesi: 5 yıllık retrospektif çalışma. *7tepe Klinik Dergisi*, 15(3), 298-304.
- Yang, H., Jo, E., Kim, H. J., Cha, I.-h., Jung, Y.-S., Nam, W., Kim, J.-Y., Kim, J.-K., Kim, Y. H., & Oh, T. G. (2020). Deep learning for automated detection of cyst and tumors of the jaw in panoramic radiographs. *Journal of clinical medicine*, 9(6), 1839.

- Yesiltepe, S., Bayrakdar, I. S., Orhan, K., Çelik, Ö., Bilgir, E., Aslan, A. F., Odabaş, A., Costa, A. L. F., & Jagtap, R. (2022). A deep learning model for idiopathic osteosclerosis detection on panoramic radiographs. *Medical Principles and Practice*, 31(6), 555-561.
- Yilmaz, E. (2018). *Periapikal kist ve keratokistik odontojenik tümör lezyonlarının yarı otomatik bölütlenmesi ve sınıflandırılması* (Publication Number 523454) [Doktora tezi, Karadeniz Teknik Üniversitesi].
- Yilmaz, E., Kayikcioglu, T., & Kayipmaz, S. (2017). Computer-aided diagnosis of periapical cyst and keratocystic odontogenic tumor on cone beam computed tomography. *Computer methods and programs in biomedicine*, 146, 91-100.
- Yilmaz, S. (2021). *Panoramik radyografi kullanılarak iki farklı derin öğrenme metodunun dişlerin sınıflandırılması üzerindeki performanslarının karşılaştırılması olarak incelenmesi* (Publication Number 706692) [Diş hekimliği uzmanlık tezi, Erciyes Üniversitesi].
- Yu, H., Cho, S., Kim, M., Kim, W., Kim, J., & Choi, J. (2020). Automated skeletal classification with lateral cephalometry based on artificial intelligence. *Journal of dental research*, 99(3), 249-256.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and control*, 8(3), 338-353.
- Zakeri, V., Arzanpour, S., & Chehroudi, B. (2014). Discrimination of tooth layers and dental restorative materials using cutting sounds. *IEEE Journal of Biomedical and Health Informatics*, 19(2), 571-580.
- Zhang, Q., Yang, L. T., Chen, Z., & Li, P. (2018). A survey on deep learning for big data. *Information Fusion*, 42, 146-157.

EKLER

Ek-1. Etik Bildirim ve İntihal Beyan Formu

	SAĞLIK BİLİMLERİ ENSTİTÜSÜ Graduate School of Health Sciences	
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU¹		
Öğrencinin Adı ve Soyadı	Zeynep TURANLI TOSUN	
Öğrencinin Numarası		
Ana Bilim Dalı	Ağız, Diş ve Çene Radyolojisi	
Öğrencinin Kayıtlı Olduğu Program Türü	Doktora	
Yukarıda bilgileri verilen tezin intihal tespit yazılımıyla (Turnitin) yapılan tarama sonucunda elde edilen benzerlik oranları aşağıdaki gibidir. Beyan edilen bilgilerin doğru olduğunu, aksi hâlde doğacak hukuki sorumlulukları kabul ve beyan ederiz.		
Bölümler	Benzerlik Oranı	Maksimum Benzerlik Oranları
I. Giriş	%0	% 15
II. Genel Bilgiler	%3	% 35
III. Materyal ve Metot	%0	% 35
IV. Bulgular	%4	% 15
V. Tartışma	%0	% 20
<i>Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5' den büyük olmaması gerekir.</i>		

Ek-2. Etik Kurul Onay Formu



T.C.
ATATÜRK ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ DEKANLIĞI
ETİK KURULU

Oturum Tarihi: 02/12/2022
Oturum Sayısı: 11/ 2022

KARAR

SORUMLU ARAŞTIRMACI	Prof. Dr. Muhammed Akif SÜMBÜLLÜ Arş. Gör. Dt. Zeynep TURANLI TOSUN
Araştırmamanın Açık Adı	<i>Maksillofasial Bölgede Radyoopak ve Radyolusent Görüntü Veren Lezyonlarda Panoramik Radyografinin Etkinliğinin Yapay Zeka Modeli Üzerinde Değerlendirilmesi</i>
Karar No	89.
Alınan Karar	Prof. Dr. Muhammed Akif SÜMBÜLLÜ danışmanlığında doktora öğrencilerinden Arş. Gör. Dt. Zeynep TURANLI TOSUN tarafından yürütülecek olan <i>“Maksillofasial Bölgede Radyoopak ve Radyolusent Görüntü Veren Lezyonlarda Panoramik Radyografinin Etkinliğinin Yapay Zeka Modeli Üzerinde Değerlendirilmesi”</i> başlıklı Doktora tezi Sağlık Sağlık Bakanlığı tarafından yayımlanan 19 Ağustos 2011 tarih ve 28030 sayılı “Klinik Araştırmalar Hakkındaki Yönetmelik” hükümlerine bağlı kalınarak yapılmak şartıyla; kabul edilmesinde bilimsel ve etik açıdan sakınca olmadığına mevcudun <i>oy birliği ile karar verildi</i>

Ek-3. Tez Adı Değişikliği Bildirim Formu



SAĞLIK BİLİMLERİ ENSTİTÜSÜ
Graduate School of Health Sciences

TEZ ADI DEĞİŞİKLİĞİ BİLDİRİM FORMU

Öğrencinin Adı ve Soyadı	Zeynep TURANLI TOSUN
Ana Bilim Dalı	Ağız, Diş ve Çene Radyolojisi
Öğrencinin Kayıtlı Olduğu Program Türü	Doktora

Ana Bilim Dalı seçmek için tıklayınız **Ana Bilim Dalı Başkanlığına**

Danışmanlığımı yürüttüğüm ve yukarıda bilgileri yazılı olan ana bilim dalımız öğrencisinin tez adı aşağıda belirtilen şekilde değiştirilmiştir. Bilgilerinize arz ederim. 06.09.2024

Prof. Dr. Muhammed Akif ŞÜMBÜLLÜ
İmza

Değişiklik Türü	Tez adı değişikliği ☒
Tezin Eski Adı	MAKSİLLOFASİYAL BÖLGEDE RADYOOPAK VE RADYOLUSENT GÖRÜNTÜ VEREN LEZYONLARDA PANORAMİK RADYOGRAFİNİN ETKİNLİĞİNİN YAPAY ZEKA MODELİ ÜZERİNDE DEĞERLENDİRİLMESİ
Tezin Yeni Adı	MAKSİLLOFASİYAL BÖLGEDE RADYOOPAK VE RADYOLUSENT GÖRÜNTÜ VEREN LEZYONLARDA YAPAY ZEKA MODELLERİNİN ETKİNLİĞİNİN PANORAMİK RADYOGRAFİLER ÜZERİNDE DEĞERLENDİRİLMESİ
Tezin İngilizce Adı	THE EFFECTIVENESS OF ARTIFICIAL INTELLIGENCE MODELS ON RADIOPAK AND RADIOLUCENT LESIONS IN THE MAXILLOFACIAL REGION ON PANORAMIC RADIOGRAPHIES
Değişikliğin Gerekçesi	Jüri üyelerinden Prof. Dr. Özkan MİLOĞLU tarafından değişiklik talep edildi. Diğer jüri üyeleri tarafından da bu değişikliğin uygunluğuna karar verildi.