



BEZMİÂLEM VAKIF ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ
ANABİLİM DALI

DERİN ÖĞRENME İLE MANYETİK REZONANS GÖRÜNTÜLERİ
ÜZERİNDEN TEMPOROMANDİBULAR EKLEM YAPISAL
BİLEŞENLERİNİN SEGMENTASYONU VE ANTERİORA
KONUMLANMIŞ DİSKİN TESPİTİ

UZMANLIK TEZİ
BÜŞRA SINMAZ

AĞIZ DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

TEZ DANIŞMANI: DR. ÖĞRETİM ÜYESİ ELİFHAN ALAGÖZ

EKİM 2024



BEZMİÂLEM VAKIF ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ
ANABİLİM DALI

DERİN ÖĞRENME İLE MANYETİK REZONANS GÖRÜNTÜLERİ
ÜZERİNDEN TEMPOROMANDİBULAR EKLEM YAPISAL
BİLEŞENLERİNİN SEGMENTASYONU VE ANTERİORA
KONUMLANMIŞ DİSKİN TESPİTİ

UZMANLIK TEZİ
BÜŞRA SINMAZ

AĞIZ DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

TEZ DANIŞMANI: DR. ÖĞRETİM ÜYESİ ELİFHAN ALAGÖZ

EKİM 2024

TEŞEKKÜR

Uzmanlık eğitimim süresince bilgi, birikim ve tecrübeleriyle yol gösteren, mesleki gelişimime katkı sağlayan, özverisi, çalışkanlığı ve iş disiplini örnek aldığım, tezimin konu seçiminden tamamlanmasına kadar tüm aşamalarında büyük emek harcayan, zamanını ve enerjisini benden hiçbir zaman esirgemeyen ve tüm bunları sonsuz bir nezaket ve samimiyetle yapan, değerli tez danışman hocam Sayın Dr. Öğretim Üyesi Elifhan ALAGÖZ'e,

Uzmanlık eğitimim süresince bilgi ve klinik deneyimlerini bizimle paylaşan Anabilim Dalı başkanımız, Sayın Dr. Öğretim Üyesi İrfan SARICA'ya,

Hem asistanlık hem de hocalık süreçlerine tanıklık ettiğim, ikisini de özveriyle yerine getiren, bilgi birikimini bizimle cömertçe paylaşan, kendisinden çok şey öğrendiğim, hekimliğini her yönüyle örnek aldığım, her konuda fikrine sonsuz güvendiğim değerli hocam Uzm. Dt. Nilüfer Karaçay'a,

Tanımdan sonsuz mutluluk duyduğum, nezaketine ve insanlığına hayran olduğum, klinik eğitimimde bilgi birikiminden faydalanma şansını bulduğum değerli kıdemlim Uzm. Dt. Ayşe Meryem Geçimli'ye,

Uzmanlık eğitimime beraber başladığımız, süreci keyifli bir hale getiren, fakülteyi güzelleştiren ve her zaman desteklerini hissettiğim değerli çalışma arkadaşlarım Dt. Ebrar Ersarı, Dt. Enes Ergin Oruç, Dt. Emine Rana Sarıkaya, Dt. Nilüfer Gürsoy ve birlikte çalıştığımız kısa zamanda çok güzel anılar biriktirdiğimiz Dt. Neslihan Göksu'ya,

Uzmanlık eğitimimin son dönemlerinde dahil olan ve birlikte çalışmaktan keyif aldığım, pozitif enerjisiyle bizi neşelendiren sevgili Dt. Yezdan Kınalı'ya,

Beni büyüten, yetiştiren ve her zaman destekleyen, maddi manevi fedakarlıklarla bugünlere getiren sevgili anneme ve canım kardeşlerime

Sonsuz minnet ve teşekkürlerimi sunarım.

BEYAN

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

Büşra SINMAZ

İÇİNDEKİLER

Sayfa

TEŞEKKÜR	iii
BEYAN.....	iv
İÇİNDEKİLER	v
SEMBOLLER ve KISALTMALAR	ix
TABLO LİSTESİ	x
ŞEKİL LİSTESİ.....	xi
ÖZET.....	xiv
SUMMARY	xvi
1.GİRİŞ VE AMAÇ	1
2.GENEL BİLGİLER.....	3
2.1 TME Anatomisi.....	3
2.1.1 Mandibular kondil anatomisi	4
2.1.2 Glenoid fossa anatomisi	5
2.1.3 Artiküler eminens anatomisi	5
2.1.4 Artiküler disk anatomisi	6
2.1.5 Temporomandibular eklemin ligamentleri.....	7
2.1.5.1 Kollateral (diskal) ligament.....	8
2.1.5.2 Kapsüler ligament	9
2.1.5.3 Temporomandibular ligament	9
2.1.5.4 Sfenomandibular ligament	10
2.1.5.5 Stylomandibular ligament	10
2.1.6 Temporomandibular eklemin fonksiyonunda etkili kaslar.....	11
2.1.6.1 Masseter kas	11
2.1.6.2 Temporal kas	12
2.1.6.3 Medial pterygoid kas	13
2.1.6.4 Lateral pterygoid kas	14
2.1.7 Temporomandibular eklemin innervasyonu.....	15

2.1.8 Temporomandibular eklemin vaskülarizasyonu	15
2.2 TME Hastalıkları.....	16
2.2.1 Temporomandibular eklem hastalıklarının sınıflaması.....	17
2.2.2 Kondil–disk kompleksindeki düzensizlikler	19
2.2.2.1 Redüksiyonlu disk deplasmanı	20
2.2.2.2 Aralıklı kilitlenme ile birlikte redüksiyonlu disk deplasmanı ..	21
2.2.2.3 Redüksiyonsuz disk deplasmanı.....	21
2.3 TME Görüntüleme	22
2.3.1 Direkt radyografiler	22
2.3.1.1 Lateral oblik transkraniyal radyografi.....	23
2.3.1.2 Transmaksiller radyografi	23
2.3.1.3 Transfarengeal radyografi	24
2.3.1.4 Transorbital radyografi.....	24
2.3.1.5 Submentoverteks radyografi.....	24
2.3.1.6 Reverse towne radyografi.....	24
2.3.1.7 Posteroanterior radyografi.....	25
2.3.1.8 Lateral sefalometrik radyografi	25
2.3.2 Panoramik radyografi	25
2.3.3 Konvansiyonel tomografi	27
2.3.4 Bilgisayarlı tomografi	27
2.3.5 Konik ışınlı bilgisayarlı tomografi	29
2.3.6 Artrografi.....	30
2.3.7 Ultrasonografi.....	31
2.3.8 Manyetik rezonans görüntüleme	32
2.4 Yapay Zekâ Nedir?	34
2.4.1 Yapay zekânın tarihçesi.....	34
2.4.2 Makine öğrenmesi	35
2.4.2.1 Denetimli öğrenme	36
2.4.2.2 Denetimsiz öğrenme.....	36
2.4.2.3 Pekiştirmeli öğrenme.....	36
2.4.3 Yapay sinir ağları	36
2.4.3.1 Yapay sinir ağı modelleri	38
2.4.3.2 Yapay sinir ağı kullanım alanları	39

2.4.5 Konvolüsyonel sinir ağları	40
2.4.5.1 Konvolüsyonel sinir ağını oluşturan katmanlar	42
2.4.6 Derin öğrenme modelleri.....	43
2.4.6.1 LeNet.....	44
2.4.6.2 AlexNet	44
2.4.6.3 ZF Net	44
2.4.6.4 VGG Net	44
2.4.6.5 GoogLeNet.....	44
2.4.6.6 ResNet	45
2.4.6.7 Dense-Net.....	45
2.4.6.8 U-Net.....	45
2.4.6.9 R-CNN	46
2.4.6.10 YOLO.....	46
2.4.7 Derin öğrenme kütüphaneleri.....	48
2.4.8 Diş hekimliğinde yapay zekâ kullanım alanları	49
3.GEREÇ VE YÖNTEMLER.....	51
3.1 Görüntülerin Seçilmesi	51
3.2 Radyografik Veri Setlerinin Elde Edilmesi.....	52
3.3 Görüntü Değerlendirmesi.....	52
3.4 Derin Öğrenme Mimarisi	58
3.5 Model Geliştirilmesi	59
3.6. Eğitim Aşaması	59
3.7 İstatiksel Analiz.....	60
3.7.1. Karmaşıklık matrisi hesaplama prosedürü	60
3.8 Performans Değerlendirme	61
3.9 Kesinlik- Duyarlılık Eğrisi (PR Eğrisi, Precision-Recall Curve).....	62
4.BULGULAR.....	64
4.1 PR Eğrisi	71
4.2 mAP Değerleri	76
5.TARTIŞMA	81
5.1 Gereç ve Yöntemler Tartışması	81
5.2 Bulguların Tartışılması	86
6.SONUÇLAR	94

7.KAYNAKÇA	96
8.EKLER.....	107
9.ÖZGEÇMİŞ.....	109



SEMBOLLER VE KISALTMALAR

2D	: İki boyutlu
3D	: Üç boyutlu
Ark.	: Arkadaşları
ADA	: Amerikan Diş Hekimleri Birliği
AI	: Artificial Intelligence
AP	: Average Precision/Ortalama Kesinlik
BT	: Bilgisayarlı Tomografi
CAD/CAM	: Computer-Aided Design/Computer-Aided Manufacturing
CNN	: Convolutional Neural Network/Evrişimli Sinir Ağları
DN	: Doğru Negatif
DP	: Doğru Pozitif
FC	: Fully Connected Layer/ Tam Bağlı Katmanlar
GPU	: Graphics Processing Unit
IoU	: Intersection Over Union
KIBT	: Konik Işınlı Bilgisayarlı Tomografi
kHz	: kilohertz
mAP	: Mean Average Precision/Ortalama Kesinlik Değerlerinin Ortalaması
MHz	: megahertz
MR	: Manyetik Rezonans
MRG	: Manyetik Rezonans Görüntüleme
MSBT	: Multislice Bilgisayarlı Tomografi
lp/mm	: line pairs per millimeter
LPK	: Lateral pterygoid kas
LSTM	: Uzun Kısa Süreli Bellek
PANet	: Path aggregation network
PR	: Precision-Recall
R-CNN	: Bölge tabanlı CNN
RBM	: Kısıtlı Boltzmann Makinesi
RDD	: Redüksiyonlu disk deplasmanı
RDC-TMD	: Temporomandibular Bozukluklar için Araştırma Teşhis Kriterleri
ReLU	: Rectified Linear Unit/ Düzeltilmiş Doğrusal Birimler
RF	: Radyofrekans
RNN	: Recurrent Neural Network/ Rekürrent Sinir Ağları
ROI	: Region of interest/ İlgili bölge
RSDD	: Redüksiyonsuz disk deplasmanı
TME	: Temporomandibular eklem
TMEH	: Temporomandibular eklem hastalıkları
TML	: Temporomandibular ligament
USG	: Ultrasonografi
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları
YOLO	: You Only Look Once
µSv	: mikroSievert

TABLO LİSTESİ

Sayfa

Tablo 2.1 Okeson'un TMEH sınıflaması [3]	18
Tablo 2.2 R-CNN, Fast R-CNN ve Faster R-CNN modellerinin karşılaştırılması [87].....	46
Tablo 3.1: Çalışmada kullanılan veri seti sayıları	60
Tablo 3.2: İkili sınıflandırma için karmaşıklık matrisi	61
Tablo 4.1: YOLOv5 ve YOLOv8 modellerinin mandibular kondil, glenoid fossa, artiküler eminens segmentasyonları için DP, YP ve YN değerleri.....	70
Tablo 4.2: YOLOv5 ve YOLOv8 modellerinin normal konumdaki artiküler disk ve anterior konumdaki artiküler disk segmentasyonları için DP, YP ve YN değerleri.....	70
Tablo 4.3: YOLOv5 ve YOLOv8 modellerinin mandibular kondil, glenoid fossa, artiküler eminens segmentasyonları için duyarlılık, kesinlik ve F1 skoru performans ölçüm değerleri	71
Tablo 4.4: YOLOv5 ve YOLOv8 modellerinin normal konumdaki artiküler disk ve anterior konumdaki artiküler disk segmentasyonları için duyarlılık, kesinlik ve F1 skoru performans ölçüm değerleri.	71
Tablo 4.5 YOLOv5 ve YOLOv8 için mAP_0.5 değerleri	77

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: TME anatomisi [11].....	3
Şekil 2.2: Mandibular kondilin anterior görünümü [3].....	5
Şekil 2.3: TME'nin kemik yapıları [3].....	6
Şekil 2.4: Artiküler diskin bölümleri; süperior ve inferior retrodiskal laminalar [14].....	7
Şekil 2.5: Medial diskal ligament (MDL), lateral diskal ligament (LDL) [3]..	8
Şekil 2.6: Kapsüler ligament [3].	9
Şekil 2.7: Temporomandibular ligamentin dış oblik (OOP) ve iç horizontal (IHP) bölümleri [3].	10
Şekil 2.8: Sfenomandibular ligament ve stylomandibular ligament [16].....	11
Şekil 2.9: TME fonksiyonunda rol oynayan dört ana çiğneme kası [18].....	11
Şekil 2.10: Masseter kasın yüzeyel ve derin kısımları [13].	12
Şekil 2.11: Temporalis kası [19].	13
Şekil 2.12: Medial pterygoid kas ve lateral pterygoid kas, lateral ve posterior açılardan görünüşleri [11].....	14
Şekil 2.13: TME innervasyonu [21].....	15
Şekil 2.14: TME'nin vaskülarizasyonu [22].	16
Şekil 2.15: Normal disk pozisyonu [35].....	19
Şekil 2.16: Normal disk pozisyonu ve redüksiyonlu disk deplasmanı [38]...	20
Şekil 2.17: Redüksiyonsuz disk deplasmanı [38].....	22
Şekil 2.18: Panoramik radyografi.....	26
Şekil 2.19: TME grafisinde ağız açık-kapalı pozisyonda kondil ve artiküler eminens [48].....	27
Şekil 2.20: BT sagittal görüntülerde TME'nin anatomisi, (a) kemik penceresi, (b) yumuşak doku penceresi[4].....	28
Şekil 2.21: KIBT parasagittal kesitte TME'nin radyolojik anatomisi [4].....	30
Şekil 2.22: Kapalı ağız pozisyonunda USG'de artiküler disk ve kondilin görüntülenmesi [55].	32
Şekil 2.23: Yapay zekâdan derin öğrenmeye temel kavramlar.	35
Şekil 2.24: Yapay sinir hücresinin yapısı [70].	37
Şekil 2.25: CNN'ler ile sınıflandırma, tespit ve segmentasyonun diş çürüğü örneği üzerinden gösterilmesi [86].	42
Şekil 3.1: Mandibular kondilin poligon yöntemi ile etiketlenmesi.	54

Şekil 3.2: Glenoid fossanın poligon yöntemi ile etiketlenmesi.....	55
Şekil 3.3: Artiküler eminensin poligon yöntemi ile etiketlenmesi.....	56
Şekil 3.4: Normal pozisyondaki artiküler diskin poligon yöntemi ile etiketlenmesi.....	57
Şekil 3.5: Anteriora deplase artiküler diskin poligon yöntemi ile etiketlenmesi.....	58
Şekil 3.6: Kesinlik-duyarlılık (PR) eğrisi.....	63
Şekil 4.1: Mandibular kondil segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.....	64
Şekil 4.2: Mandibular kondil segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.....	65
Şekil 4.3: Artiküler eminens segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.....	65
Şekil 4.4: Artiküler eminens segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.....	66
Şekil 4.5: Glenoid fossa segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.....	66
Şekil 4.6: Glenoid fossa segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.....	67
Şekil 4.7: Normal konumdaki artiküler disk segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.....	67
Şekil 4.8: Normal konumdaki artiküler disk segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.....	68
Şekil 4.9: Anteriora deplase artiküler disk segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.....	69
Şekil 4.10 Anteriora deplase artiküler disk segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.....	69
Şekil 4.11: YOLOv5 modelinin mandibular kondil segmentasyonu için PR eğrisi.....	72
Şekil 4.12: YOLOv8 modelinin mandibular kondil segmentasyonu için PR eğrisi.....	72
Şekil 4.13: YOLOv5 modelinin artiküler eminens segmentasyonu için PR eğrisi.....	73
Şekil 4.14: YOLOv8 modelinin artiküler eminens segmentasyonu için PR eğrisi.....	73
Şekil 4.15: YOLOv5 modelinin artiküler fossa segmentasyonu için PR eğrisi.....	74
Şekil 4.16: YOLOv8 modelinin artiküler fossa segmentasyonu için PR eğrisi.....	74
Şekil 4.17: YOLOv5 modelinin normal konumdaki artiküler disk segmentasyonu için PR eğrisi.....	75
Şekil 4.18: YOLOv8 modelinin normal konumdaki artiküler disk segmentasyonu için PR eğrisi.....	75

Şekil 4.19: YOLOv5 modelinin anteriora deplase artiküler disk segmentasyonu için PR eğrisi.....	76
Şekil 4.20: YOLOv8 modelinin anteriora deplase artiküler disk segmentasyonu için PR eğrisi.....	76
Şekil 4.21: a. mandibular kondil segmentasyonu, b. YOLOv8'in mandibular kondil tahmini, c. artiküler eminens segmentasyonu, d. YOLOv8'in artiküler eminens tahmini, e. artiküler fossanın segmentasyonu, f. YOLOv8 modelinin artiküler fossa tahmini	77
Şekil 4.22: a. normal konumdaki artiküler diskin segmentasyonu, b. YOLOv8'in normal konumdaki artiküler disk tahmini, c. anteriora deplase artiküler diskin segmentasyonu, d. YOLOv8'in anteriora deplase artiküler disk tahmini	78
Şekil 4.23: a. mandibular kondil segmentasyonu, b. YOLOv5'in mandibular kondil tahmini, c. artiküler eminens segmentasyonu, d. YOLOv5'in artiküler eminens tahmini, e. artiküler fossanın segmentasyonu, f. YOLOv5 modelinin artiküler fossa tahmini	79
Şekil 4.24: a. normal konumdaki artiküler diskin segmentasyonu, b. YOLOv5'in normal konumdaki artiküler disk tahmini, c. anteriora deplase artiküler diskin segmentasyonu, d. YOLOv5'in anteriora deplase artiküler disk tahmini	80

DERİN ÖĞRENME İLE MANYETİK REZONANS GÖRÜNTÜLERİ ÜZERİNDEN TEMPOROMANDİBULAR EKLEM YAPISAL BİLEŞENLERİNİN SEGMENTASYONU VE ANTERİORA KONUMLANMIŞ DİSKİN TESPİTİ

ÖZET

Temporomandibular eklem hastalıkları (TMEH) toplumda yaygın olarak görülmektedir ve bu hastalıkların tanısında doğru bir görüntüleme yöntemi kullanmak, klinik başarı açısından kritik öneme sahiptir. Manyetik rezonans görüntüleme (MRG) temporomandibular eklem (TME) yumuşak doku rahatsızlıklarının teşhisinde altın standart olarak kabul görmektedir. Fakat TME'ye ait MR görüntülerinin yorumlanması uzman hekimler için bile kolay olmamaktadır. MRG'nin yorumlanmasında standardizasyon sağlanabilmesi için yapay zekâ sistemleri kullanılabilir.

Bu çalışmanın temel amacı, TME bölgesinin yapısal bileşenlerinin, T2 ağırlıklı sagittal MR görüntüleri kullanılarak derin öğrenme modelleri ile otomatik olarak segmente edilmesidir. Çalışmada mandibular kondil, artiküler eminens, glenoid fossa ve artiküler diskin, normal ve anteriora deplase pozisyonlarındaki segmentasyonu yapılmıştır. Bu segmentasyon sürecinde YOLOv5 ve YOLOv8 modellerinin performansları karşılaştırılarak, hangi modelin bu yapılar üzerinde daha yüksek doğruluk ve hassasiyetle sonuçlar verdiği araştırılmıştır. Bu amaç doğrultusunda, yapay zekâ tabanlı yaklaşımların klinik uygulamalarda teşhis süreçlerine katkı sağlayabileceği hipotezi test edilmiştir.

Çalışmada, TME bölgesine ait 901 adet T2 ağırlıklı sagittal MR görüntüsünden oluşan bir veri seti kullanılmıştır. Bu görüntüler üzerinden mandibular kondil, artiküler eminens, glenoid fossa ve artiküler disk anatomik yapılarının segmentasyonu, yapay zekâ destekli Craniocatch uygulamasında, YOLOv5 ve YOLOv8 derin öğrenme modelleri ile gerçekleştirilmiştir. Model performansları, duyarlılık, kesinlik ve F1 skoru gibi metriklerle değerlendirilmiştir.

Mandibular kondil segmentasyonunda, YOLOv5'in duyarlılığı 1 iken, YOLOv8'in duyarlılığı 0,98'dir. YOLOv5'in kesinlik değeri 0,98, YOLOv8'in kesinlik değeri ise 0,97'dir. F1 skoru açısından, YOLOv5 0,99, YOLOv8 ise 0,98 değerlerine sahiptir. Artiküler eminens segmentasyonunda ise hem YOLOv5 hem de YOLOv8'in duyarlılık değerleri 0,98 olarak ölçülmüştür. Kesinlik açısından, YOLOv5 0,96, YOLOv8 ise 0,98 olarak hesaplanmıştır. F1 skoru, YOLOv5 için 0,97, YOLOv8 için ise 0,98'dir. Glenoid fossa segmentasyonunda YOLOv5'in duyarlılığı 0,82, YOLOv8'in duyarlılığı ise 0,96'dır. Kesinlik değeri YOLOv5 için 0,90, YOLOv8 için ise 0,98'dir. F1 skoru ise YOLOv5 için 0,86, YOLOv8 için 0,97'dir. Normal konumdaki artiküler diskin YOLOv5 modelindeki duyarlılık değeri 1, kesinlik değeri 1, F1 skoru 1; YOLOv8 modelindeki duyarlılık değeri 0,98, kesinlik değeri 1, F1 skoru 0,99 olarak bulunmuştur. Anterior konumdaki artiküler diskin YOLOv5 modelindeki duyarlılık değeri 1, kesinlik değeri 0,96, F1 skoru 0,98; YOLOv8 modelindeki duyarlılık değeri 0,96, kesinlik değeri 0,86, F1 skoru 0,90 olarak bulunmuştur.

Bu çalışma, yapay zekâ tabanlı YOLOv5 ve YOLOv8 modellerinin TME yapılarının otomatik segmentasyonu konusunda yüksek başarı elde ettiğini göstermektedir. Özellikle YOLOv5 modeli, mandibular kondil ve anteriora deplase disk segmentasyonunda daha yüksek performans sergilemiştir. YOLOv8 ise glenoid fossa ve artiküler eminens segmentasyonunda daha başarılı sonuçlar vermiştir. Elde edilen bulgular, bu modellerin klinik ve radyolojik teşhis süreçlerine entegre edilebileceğini ve teşhis sürecini hızlandırarak hekimlere önemli bir destek sağlayabileceğini göstermektedir. Ayrıca, TME bölgesine ilişkin daha ileri düzey yapay zekâ modellerinin geliştirilmesiyle, hastalıkların erken teşhisi ve tedavi süreçlerinde daha etkin sonuçlar elde edilebilecektir.

Anahtar kelimeler: Yapay zekâ, derin öğrenme, MRG, TME, YOLO

SEGMENTATION OF STRUCTURAL COMPONENTS OF THE TEMPOROMANDIBULAR JOINT AND DETECTION OF ANTERIORLY POSITIONED DISCS IN MAGNETIC RESONANCE IMAGES USING DEEP LEARNING

SUMMARY

Temporomandibular joint disorders (TMJDs) are commonly seen in the population, and using the correct imaging method in diagnosing these diseases is critical for clinical success. Magnetic Resonance Imaging (MRI) is widely recognized as the gold standard for diagnosing soft tissue disorders of the temporomandibular joint (TMJ). However, interpreting TMJ MRI images is challenging even for expert clinicians. Artificial intelligence (AI) systems can be used to standardize MRI interpretation.

The primary aim of this study is to automatically segment the structural components of the TMJ region using deep learning models on T2-weighted sagittal MRI images. This study involved segmenting the mandibular condyle, articular eminence, glenoid fossa, and articular disc in both normal and anteriorly displaced positions. The performance of YOLOv5 and YOLOv8 models in this segmentation process was compared to determine which model provides higher accuracy and precision for these structures. The hypothesis tested is that AI based approaches can contribute to diagnostic processes in clinical applications.

A dataset comprising 901 T2-weighted sagittal MRI images of the TMJ region was used in the study. Segmentation of the anatomical structures -mandibular condyle, articular eminence, glenoid fossa, and articular disc- was performed using the AI supported Craniocatch (Eskisehir, Turkiye) application with YOLOv5 and YOLOv8

deep learning models. Model performance was evaluated using metrics such as recall, precision, and F1 score.

In mandibular condyle segmentation, YOLOv5 had a sensitivity of 1, while YOLOv8 had a sensitivity of 0.98. The precision of YOLOv5 was 0.98, and YOLOv8's precision was 0.97. In terms of the F1 score, YOLOv5 scored 0.99, and YOLOv8 scored 0.98. For the segmentation of the articular eminence, both YOLOv5 and YOLOv8 had a sensitivity of 0.98. In terms of precision, YOLOv5 scored 0.96, while YOLOv8 scored 0.98. The F1 score was 0.97 for YOLOv5 and 0.98 for YOLOv8. In glenoid fossa segmentation, YOLOv5 had a sensitivity of 0.82, while YOLOv8 had a sensitivity of 0.96. The precision for YOLOv5 was 0.90, while it was 0.98 for YOLOv8. The F1 score was 0.86 for YOLOv5 and 0.97 for YOLOv8. In the segmentation of the articular disc in the normal position, YOLOv5 achieved a sensitivity of 1, precision of 1, and F1 score of 1, while YOLOv8 had a sensitivity of 0.98, precision of 1, and F1 score of 0.99. For the anteriorly displaced articular disc, YOLOv5 had a sensitivity of 1, precision of 0.96, and F1 score of 0.98, while YOLOv8 had a sensitivity of 0.96, precision of 0.86, and F1 score of 0.90.

This study demonstrates that AI-based YOLOv5 and YOLOv8 models achieve high success in the automatic segmentation of TMJ structures. Specifically, YOLOv5 exhibited superior performance in segmenting the mandibular condyle and anteriorly displaced disc, while YOLOv8 provided better results for the segmentation of the glenoid fossa and articular eminence. The findings suggest that these models can be integrated into clinical and radiological diagnostic processes, potentially accelerating diagnosis and offering significant support to clinicians. Furthermore, the development of more advanced AI models for the TMJ region could lead to more effective early diagnosis and treatment outcomes.

Keywords: Artificial intelligence, deep learning, MRI, TMJ, YOLO

1. GİRİŞ VE AMAÇ

Temporomandibular eklem hastalıkları (TMEH), temporomandibular eklemi (TME) ve çevresindeki kas-iskelet sistemini etkileyen rahatsızlıkları kapsayan geniş klinik problemler grubudur. TMEH belirtileri arasında TME ağrısı, çene hareketleri esnasında eklemden ses gelmesi, trismus, çeneyi açarken deviasyon ya da defleksiyon, çiğneme kaslarında ağrı ve genel miyofasiyal ağrı bulunmaktadır [1]. Bu hastalıklar, toplumda yaygın olarak görülmekte ve orofasiyal bölgede dişsel kökenli olmayan kronik ağrı şikayetleri arasında en yaygın sebep olarak kabul edilmektedir [2].

Bu hastalıkların tanısında doğru ve güvenilir bir görüntüleme yöntemi kullanmak, klinik başarı açısından kritik öneme sahiptir. TME'nin yumuşak dokularının detaylı olarak incelenmesinde manyetik rezonans görüntüleme (MRG) altın standart olarak kabul edilmektedir [3-5]. MRG, disk deplasmanlarının teşhisi için en doğru ve temel tanı yöntemi olsa da önceki çalışmalar, uzman olmayan hekimlerin, hatta deneyimli uzmanların bile disk bozuklukları konusunda doğru MRG değerlendirmeleri yapamadığını ve TME MRG yorumlarının genellikle tutarlılık göstermediğini ortaya koymaktadır [6-8]. MRG verilerinin manuel olarak değerlendirilmesi hem zaman alıcı hem de operatör bağımlı değişkenliklere açık bir süreçtir. Bu bağlamda, derin öğrenme yöntemleri, görüntüleme verilerinin otomatik olarak analiz edilmesi ve patolojik durumların tespit edilmesi açısından büyük bir potansiyel sunmaktadır. Son yıllarda, yapay zekâ ve özellikle derin öğrenme algoritmalarının tıbbi görüntüleme uygulamalarına entegre edilmesiyle önemli ilerlemeler kaydedilmiştir. Konvolüsyonel sinir ağı- *Convolutional Neural Network* (CNN) gibi algoritmalar, karmaşık görüntü verilerinin otomatik analizini gerçekleştirerek, insan gözünün algılayamayacağı ince ayrıntıları dahi yüksek doğrulukla tespit edebilmektedir [9, 10]. TME yapısal bileşenlerinin segmentasyonu ve disk yer değişikliklerinin otomatik tespiti, klinik değerlendirme süreçlerini hızlandırma ve daha objektif sonuçlar sunma potansiyeline sahiptir.


Bu alıřma, CNN'lere dayalı bir yapay zekâ modeli olan Craniocatch (Eskiřehir, Trkiye) uygulaması kullanılarak MR grntlerinde TME'yi oluřturan anatomik yapılardan glenoid fossa, artikler eminens, mandibular kondil ve artikler diskin segmentasyonu ile anterior pozisyonadaki artikler diskin tespiti amacıyla gerekleřtirilmiřtir. Elde edilen sonuların, tanısal sreleri otomatikleřtirerek radyologlara destek saėlayacak bir deėerlendirme aracı olarak kullanılması planlanmaktadır. Ayrıca Craniocatch (Eskiřehir, Trkiye) uygulaması zerinden ėrencilerin MR grntlerinde TME anatomik noktalarını ėrenmesine yardımcı olabilir.



2. GENEL BİLGİLER

2.1 TME Anatomisi

Temporomandibular eklem; temporal kemiğin glenoid fossası ile mandibula kondili arasında yer alan ve özelleşmiş sıkı fibröz bağ dokusu yapısına sahip artiküler disk, çeşitli ligamentler ve birçok kas ile bağlantılı eklemdir [1, 11] (Şekil 2.1). TME'nin etrafı, innervasyonu ve vaskülarizasyonu yüksek, fibröz bağ dokusundan oluşan bir kapsülle çevrilidir. Eklem kapsülünün iç yüzeyi ise sinovyal sıvı üretimini sağlayan sinovyal membran ile kaplıdır. Sinovyal sıvı, nonvaskülarize yapıların beslenmesini ve fonksiyon sırasında oluşan sürtünmenin azaltılmasını sağlamaktadır [1].



Şekil 2.1: TME anatomisi [11].

Artiküler disk, eklemi alt ve üst eklem boşluğu olacak şekilde ikiye ayırmıştır. Eklem alt kompartmanı ile menteşe hareketi yapabildiğinden ginglymoid olarak kabul edilirken; üst kompartman ile kayma hareketi yapabilir ve bu nedenle artroidal eklem olarak sınıflandırılır. Bu nedenle, teknik olarak ginglymoartrodial bir eklem olarak kabul edilmiştir [3].

Temporomandibular eklemi diğer eklemlerden ayıran bazı özellikleri vardır. Bunlar;

- Her iki tarafın eklemi mandibula ile birbirine bağlı olduğundan birindeki hareket veya fonksiyonel değişiklikler diğerini de etkiler. TME'nin normal çalışması için bilateral senkronizasyon önemlidir. Ayrıca hareket sadece kemik, kas ve ligamentlerin şekli ile değil, dişlerin oklüzyonu tarafından da yönlendirilir [12].

- Temporomandibular eklemin artiküler yüzeyleri hyalin kıkırdak yerine fibrokartilajla kaplıdır. Fibrokartilaj doku, hyalin kartilaja göre dejeneratif değişikliklere daha dirençlidir [12].

- Temporomandibular eklemin kendine özel bir diğer özelliği mandibulanın kemik gelişiminde önemli bir rolü olan eklem kapsülü içinde büyüme merkezi aktivitesini içeren tek eklem olmasıdır [12].

2.1.1 Mandibular kondil anatomisi

Temporomandibular eklemin mandibular bileşeni, mandibular ramusa dar bir boyunla bağlı, mediolateral olarak 18-23 mm ve anteroposterior olarak 8-10 mm ölçülerinde bir kondil başından oluşur [3]. Anteriordan bakıldığında kutup dediğimiz medial ve lateral çıkıntılara sahiptir ve genellikle medial kutbu lateralden daha belirgindir (Şekil 2.2). Kondilin eklem yüzeyi mediolateral yönde daha hafif olmakla beraber, anteroposterior ve mediolateral yönde dışbükeydir [3]. Eklem yüzeyinin hemen altındaki medial kısmında, pterygoid fovea olarak isimlendirilen belirgin bir çöküntü vardır. Pterygoid foveaya, kondiler translasyon sırasında mandibulanın protrüzyonuna yardımcı olan lateral pterygoid kasın (LPK) alt karnı yerleşmektedir [1].



Şekil 2.2: Mandibular kondilin anterior görünümü [3].

Medial kutup (MP), lateral kutup (LP)'tan daha belirgindir.


2.1.2 Glenoid fossa anatomisi

Glenoid fossa temporal kemiğin skuamöz kısmında yer alan içbükey bir çöküntü alanıdır [13] (Şekil 2.3). Glenoid fossa yerine mandibular fossa veya artiküler fossa terimleri de kullanılmaktadır. Mandibular fossanın anteriorunda artiküler eminens, posteriorunda mediolateral yönde uzanan skuamotimpanik fissür bulunur. Bu fissür mediale doğru uzandıkça, önde petroskuamöz fissür ve arkada petrotimpanik fissür olarak ikiye ayrılır [3]. Glenoid fossanın tavanı oldukça ince yapıdadır. Bu glenoid fossanın, TME'de yer alan önemli bir kemik yapısı olmasına rağmen eklemin stres taşımakla görevli bir parçası olmadığını gösterir. Bu ince kemik plakasının üzerinde orta kranial fossa bulunur [11].

2.1.3 Artiküler eminens anatomisi

Artiküler eminens, glenoid fossanın hemen önünde bulunan ve konveks bir yapıya sahip olan, zigomatik proçesin tabanındaki güçlü kemik çıkıntısıdır [3, 11] (Şekil 2.3). Normal çene hareketleri esnasında kondil ve disk, ileri geri kayma hareketi yaparken, artiküler eminens geçer [4]. Artiküler eminensin konvekslik derecesi oldukça değişkendir ve bu yüzeyin dikliği mandibula anteriora konumlandırıldığı zaman kondil yolunu belirlemektedir. Glenoid fossanın tavanı ince yapıda olduğu için ekleme gelecek ağır kuvvetleri taşıyabilecek yapıda değilken, artiküler eminens kalın yoğun kemikten oluşur ve bu tür kuvvetleri tolere etme olasılığı daha yüksektir [3]. Artiküler eminens bazen, temporal kemiğin mastoid proçesi gibi hava dolu boşluklar içerebilir [4].

Artiküler tüberkül, artiküler eminensin lateral kısmında bulunur ve bu yapı kapsül ile lateral temporomandibular ligamentin (TML) bağlanma noktasını sağlar [11].



Şekil 2.3: TME'nin kemik yapıları [3].

Artiküler eminens (AE) ve mandibular fossa (MF).

2.1.4 Artiküler disk anatomisi


Artiküler disk, mandibular kondil ve glenoid fossa arasında yer alan, TME'yi işlevsel olarak farklı iki boşluğa bölen (üst ve alt eklem boşlukları) ve yoğun fibroz bağ dokusundan oluşan yapıdır [11]. Damar ve sinir içermemesi eklem uygulanan basınçları absorbe etmesini sağlayan bir adaptasyondur [1].

Lateralden bakıldığında anatomik olarak üç bölgeye ayrılmıştır [3, 14] (Şekil 2.4). Bu bölgelerden en ince olanı diskin orta bölümü olup intermediat zon olarak adlandırılmaktadır. Disk intermediat zonun hem önünde hem de arkasında önemli ölçüde kalınlaşmakta olup posterior bant genellikle anterior banttın biraz daha kalındır[3]. Orta bölümünde incelenerek aldığı bikonkav şekli sayesinde translasyon sırasında diskin yer değiştirmesini engeller [4]. Anteriordan bakıldığında, disk medialde laterale göre genellikle daha kalındır; bu da medial tarafa doğru kondil ve artiküler fossa arasındaki mesafenin artmasından kaynaklıdır [3].

Eklem diskinin anterior bölgesinin süperior ve inferior ataçmanları, kollajen liflerle kapsüler ligamente bağlanır. Süperior ataçman temporal kemiğe; inferior ataçman ise kondile bağlanmaktadır. Disk anteriorda, kapsüler ligamentin bağlantıları arasından, süperior LPK'ya tendinöz liflerle bağlıdır. LPK'nın inferior başı ise

mandibulanın pterygoid foveasına bağlanır. Böylelikle, LPK mandibulayı anteriora çekerken, eklem diski de eklem kapsülü ile anteriora gelir [3].

Eklem diski posteriorda yüksek oranda damar ve sinir içeren gevşek bağ dokusuna bağlıdır. Bu doku, retrodiskal doku olarak bilinir. Retrodiskal dokular bilaminar zon olarak da adlandırılır (üst ve alt retrodiskal laminalar) ve sinoviyal sıvı üretiminde rol oynar [1] (Şekil 2.4). Süperior retrodiskal lamina elastik liflerden oluşmaktadır ve eklem diskini arkada timpanik plaka ile bağlar. İnferior retrodiskal lamina ise diskin posterior kenarını kondilin eklem yüzeyinin posterior kenarına bağlar. İnferior retrodiskal lamina, süperior retrodiskal lamina gibi elastik liflerden değil, esas olarak kollajen liflerden oluşur. Retrodiskal dokunun kalan kısmı, kondil ileri hareket ettikçe kanla dolan büyük bir venöz pleksusla bağlıdır [3].



Şekil 2.4: Artiküler diskin bölümleri; süperior ve inferior retrodiskal laminalar [14].

2.1.5 Temporomandibular eklem ligamentleri


Temporomandibular eklem ile ilişkili ligamentler; kondil ve disk hareketlerine sınırlama getirirler, stabilizasyon sağlarlar ve yapısal elemanların korunmasında önemli rol oynarlar. Ligamentler eklem fonksiyonuna aktif olarak katılmazlar fakat çene hareketlerinin bazılarını kısıtlayarak pasif elemanlar olarak görev yaparlar. Ligamentler, elastik olmayan kolajen bağ dokusu liflerinden meydana gelirler [1, 3].

Kollateral (diskal) ligament, kapsüler ligament ve temporomandibular ligament TME'yi destekleyen fonksiyonel ligamentlerdir. TME'nin, sfenomandibular ve stilomandibular ligament olmak üzere iki tane de aksesuar ligamenti bulunur [1, 3, 11].

2.1.5.1 Kollateral (diskal) ligament

Kollateral ligament, diskal ligament olarak da adlandırılır. Artiküler diskin medial ve lateral sınırlarını kondilin kutuplarına bağlar. Medial ve lateral diskal ligament olmak üzere iki tanedir. Medial diskal ligament, diskin medial kenarını kondilin medial kutbuna bağlarken lateral diskal ligament, diskin lateral kenarını kondilin lateral kutbuna bağlar. Bu ligamentler, eklemi mediolateral olarak alt ve üst eklem boşluklarına ayırırlar [3, 11] (Şekil 2.5).

Fonksiyonları, diskin kondilden uzaklaşmasını sınırlamak ve böylece disk-kondil kompleksinin düzgün ve senkronize hareket etmesini sağlamaktır. Diskin kondil ile anteroposterior yönde pasif olarak hareket etmesine izin verir. TME'nin, kondil ile eklem diski arasında meydana gelen menteşe hareketinden sorumludur [1].



Şekil 2.5: Medial diskal ligament (MDL), lateral diskal ligament (LDL) [3].

Artiküler disk (AD), kapsüler ligament (CL), alt eklem boşluğu (IC), lateral diskal ligament (LDL), medial diskal ligament (MDL), üst eklem boşluğu (SC).

Diskal ligamentler vaskülarizasyon ve innervasyona sahiptir. Innervasyonu, eklem pozisyonu ve hareketi hakkında bilgi sağlar. Kolajen bağ dokusu liflerinden oluştuğu için esnemezler. Bu ligamentlerin zorlanması ağrıya neden olur [3].

2.1.5.2 Kapsüler ligament

Kapsüler ligament TME'nin tamamını çevreleyerek, süperiorda mandibular fossa ve artiküler eminensin sınırları boyunca temporal kemiğe, inferiorda ise kondil boynuna bağlanır (Şekil 2.6). Kapsüler ligamentin görevi artiküler yüzeyleri disloke edebilecek medial, lateral veya inferior kuvvetlere karşı direnç göstererek eklemi bir arada tutmaktır. Kapsüler ligamentin bir diğer önemli fonksiyonu da, alt ve üst eklem boşluklarında sinovyal sıvıyı tutmaktır [1]. Kapsüler ligament iyi innerve olduğundan eklemin pozisyonu ve hareketi hakkında geri bildirim sağlar [3].




Şekil 2.6: Kapsüler ligament [3].

2.1.5.3 Temporomandibular ligament

Temporomandibular (lateral) ligament, TME'nin lateralinde bulunan ve kapsülü dışarıdan destekleyen güçlü ve sıkı liflerden oluşmaktadır. Kapsüler ve kollateral ligamentlerin iki tarafta da medial ve lateral bileşenleri bulunurken, temporomandibular ligament tektir ve karşı TME'deki ligament ile beraber çalışırlar[1]. Temporomandibular ligament, dış oblik ve iç horizontal olmak üzere farklı görevlere sahip iki ayrı bölüme ayrılmaktadır [1, 3, 11].

Dış oblik kısım, zigomatik proçes ve artiküler tüberkülün dış yüzeyinden posteroinferior yönde, kondil boyununun dış posterior yüzeyine uzanır [11]. Temporomandibular ligamentin dış oblik kısmı, rotasyon esnasında kondilin aşırı öne hareketini engelleyerek ağız açma miktarını sınırlar [3, 4]. İç horizontal kısım ise, artiküler tüberkül ve zigomatik proçesin dış yüzeyinden, horizontal olarak posteriora doğru uzanır ve kondilin lateral kutbu ile diskin posterior kısmına bağlanır [11]. Temporomandibular ligamentin iç horizontal kısmı kondilin ve diskin posterior

hareketini sınırlayarak retrodiskal dokuları korur. Ayrıca LPK'nın aşırı uzamasını ve gerilmesini engeller [3, 4].




Şekil 2.7: Temporomandibular ligamentin dış oblik (OOP) ve iç horizontal (IHP) bölümleri [3].

2.1.5.4 Sfenomandibular ligament

Sfenomandibular ligament, sfenoid kemiğin spinasından çıkar ve aşağı doğru genişleyerek mandibula ramusunun medial yüzeyindeki lingulaya tutunur [11] (Şekil 2.8). Mandibular hareketi sınırlamada belirgin bir etkisi yoktur. Bu ligament, mandibular kanaldan çıkan damar-sinir paketini, mandibular hareketler sırasında oluşabilecek basınçlardan korumaktadır [4].

2.1.5.5 Stylomandibular ligament


Stylomandibular ligament, styloid proçesten, angulus mandibulanın ve ramusun posterior sınırına uzanır (Şekil 2.8). Stylomandibular ligament, masseter kas ile medial pterygoid kas arasında seyreder. Ayrıca parotis bezi ile submandibular bezin arasındadır [11, 15]. Mandibulanın aşırı protrüziv hareketini sınırlamaya yardımcı olur [1, 11].



Şekil 2.8: Sfenomandibular ligament ve stylomandibular ligament [16].

2.1.6 Temporomandibular eklem fonksiyonunda etkili kaslar

Temporomandibular eklem fonksiyonunun önemli bileşenlerinden biri de çiğneme kaslarıdır. Baş ve boyunda çiğnemeye dahil olan birçok kas vardır ancak temel çiğneme kasları masseter, temporal, medial pterygoid ve lateral pterygoid olmak üzere dört kas çiftinden oluşmaktadır (Şekil 2.9). Embriyonik olarak, bu kaslar birinci faringeal arkın mezenşiminden gelişir ve trigeminal sinirin mandibular dalından innervasyon alırlar [17].




Şekil 2.9: TME fonksiyonunda rol oynayan dört ana çiğneme kası [18].

Temporal ve masseter kas (a), lateral ve medial pterygoid kas (b).

2.1.6.1 Masseter kas

Masseter kas, zigomatik arkta başlayan ve mandibulanın dış yüzeyine yapışan kısa dikdörtgen şeklinde bir kاستır. Yüzeyel ve derin liflerden oluşmaktadır. Yüzeyel lifler aşağı doğru ve hafifçe arkaya doğru uzanırken derin lifler dikey olarak konumlanmaktadır (Şekil 2.10). Masseter, kasıldığında mandibulayı eleve eden ve


etkili çiğneme sağlayan güçlü bir kastır. Yüzeyel lifleri protrüzyona katkıda bulunurken, derin lifleri ile kondili artiküler eminense karşı stabilize eder [3].



Şekil 2.10: Masseter kasın yüzeyel ve derin kısımları [13].

2.1.6.2 Temporal kas


Çiğneme kaslarının en büyüğü olan temporal kas, kafatasının lateral yüzeyindeki temporal fossadan ve üzerindeki temporal fasyadan köken alan yelpaze şeklinde bir kastır (Şekil 2.11). Zigomatik arkın medialinden geçer ve mandibulanın koronoid çıkıntısı ve ramus mandibulanın anterior yüzüne tutunarak sonlanır. Üç kısımdan oluşan kasın anterior lifleri vertikal, medial lifleri oblik, posterior lifleri horizontal seyredecek şekilde konumlanmıştır. Temporal kas bir bütün olarak kasıldığında mandibulayı yukarı kaldırır. Yalnızca belli bölümleri kasılırsa, mandibula aktive olan liflerin yönüne göre hareket eder. Anterior lifler kasıldığında, mandibula dikey olarak yukarı kalkar; medial lifler kasıldığında, mandibula yukarı ve geriye doğru hareket eder; posterior kısım kasıldığında, mandibula geriye doğru hareket eder [4].



Şekil 2.11: Temporalis kası [19].

2.1.6.3 Medial pterygoid kas

Medial pterygoid kas pterygoid fossadan başlayarak, ramus mandibulanın medialinde masseter kasa paralel doğrultuda aşağı, geri ve dışarı doğru uzanarak tüberositas pterygoideaya yapışmaktadır (Şekil 2.12). Medial pterygoid kas, masseter ve temporal kaslarla birlikte mandibulanın elevasyonunu sağlar. Bu kasın kasılmasıyla alt çene yükselir ve dişler okluzyona gelir. Tek taraflı olarak kasıldığında ise mandibulanın mediotrüziv hareketini sağlamaktadır [1].



Şekil 2.12: Medial pterygoid kas ve lateral pterygoid kas, lateral ve posterior açılardan görünüşleri [11].

2.1.6.4 Lateral pterygoid kas


Lateral pterygoid kas yıllarca inferior ve süperior olmak üzere iki bölüm olarak tanımlanmıştır [20]. Kas anatomik olarak yapı ve işlev bakımından tek bir bütün olarak görünse de literatürde tartışmalı bir alan olarak kalmıştır. Artık lateral pterygoidin iki bölümünün oldukça farklı işlevlere sahip olduğu anlaşılmıştır. Bu nedenle lateral pterygoid, işlevlerinin neredeyse zıt olması nedeniyle inferior lateral pterygoid ve süperior lateral pterygoid isimli iki farklı kas olarak tanımlanmıştır [3, 17].

İnferior lateral pterygoid, lateral pterygoid plağın dış yüzeyinden başlar ve kondil boynuna tutunur. Bilateral olarak kasıldığında, kondiller aşağıya, artiküler eminense doğru çekilir ve mandibula protrüze olur. Unilateral kasılma, ilgili kondilin mediotrüziv hareket etmesine ve mandibulanın karşı tarafa doğru lateral hareket etmesine neden olur. Bu kas, depresör kaslarla birlikte kasıldığında, mandibula aşağıya doğru hareket eder ve kondiller artiküler eminens üzerinde öne ve aşağıya doğru hareket eder; dolayısıyla inferior LPK, çeneyi açan tek çiğneme kası olmaktadır [3, 4].

Süperior lateral pterygoid, inferior olandan oldukça küçüktür. Sfenoid kemiğin infratemporal yüzeyinden başlayarak, neredeyse yatay bir şekilde geri ve dışa doğru uzanarak eklem kapsülüne, diske ve kondil boynuna tutunur. Bu kas kasıldığında, diski anteromediale doğru çeker. Mandibulanın aşağıya hareketi, yani çenenin açılması sırasında inaktif durumdadır. Elevatör kaslarla birlikte kasıldığında, özellikle dişler oklüzyona geldiğinde kas aktif olur ve böylelikle kapanma esnasında eklem stabilitesine yardımcı olur [3, 4].

2.1.7 Temporomandibular eklemin innervasyonu

Tüm eklemlerde olduğu gibi, TME de onu kontrol eden kaslara motor ve duyuşal innervasyonu sağlayan aynı sinir tarafından innerve olmaktadır. Innervasyonun çoğu trigeminal sinirin mandibular dalından çıkan aurikulotemporal sinir tarafından sağlanır. Masseterik sinir ve posterior derin temporal sinir tarafından da ek bir innervasyon sağlanmaktadır [3] (Şekil 2.13).




Şekil 2.13: TME innervasyonu [21].

2.1.8 Temporomandibular eklemin vaskülarizasyonu

Zengin bir vaskülarizasyonu olan TME'nin beslenmesinde esas olarak eksternal karotid arterin dalları olan süperfisyal temporal arter, orta meningeal arter ve maksiller arter rol oynar. Diğer önemli arterler arasında derin auriküler, anterior timpanik ve asendan farengeal arterler bulunur (Şekil 2.14). Venöz drenajda ise süperfisyal temporal ven, maksiller pleksus ve ptergoid pleksus görev almaktadır. Protrüzyon sırasında, retrodiskal dokunun gerilmesiyle venöz pleksus dolarken,

retrüzyon sırasında retrodiskal dokunun sıkışmasıyla venöz pleksus boşalmaktadır [3, 4].



Şekil 2.14: TME'nin vaskülarizasyonu [22].

2.2 TME Hastalıkları

Temporomandibular eklem hastalıkları (TMEH); çiğneme kaslarının, TME'nin, çevre kemik ve yumuşak doku bileşenlerinin sorunları ve bu sorunların kombinasyonlarını içeren geniş klinik problemler grubudur. TMEH belirtileri arasında TME ağrısı, çene hareketleri esnasında eklemden ses gelmesi, trismus, çeneyi açarken deviasyon ya da defleksiyon, çiğneme kaslarında ağrı ve genel miyofasiyal ağrı bulunur. TMEH prevalansının nüfusun %5'inden fazla olduğu düşünülmektedir [1]. TMEH semptomları 20-40 yaş arasında ve kadınlarda daha sık görülmektedir. Cinsiyet dengesizliğinin nedenleri tam olarak anlaşılamasa da cinsiyet hormonlarının TME disfonksiyonuna yatkınlık oluşturabileceğini öne süren hayvan ve insan çalışmaları mevcuttur [23, 24]. Ancak bu hormonlar ile TMEH'nin nedenleri arasında kesin bir bağlantı kurulamamıştır [25].

Toplumun çoğunda, çiğneme sistemi önemli bir sorun olmadan normal ve verimli bir şekilde çalışmaktadır. Bununla beraber, bazı faktörler çiğneme yapılarında işlev bozukluğuna neden olarak normal işlevi kesintiye uğratabilir. Bu faktörlere etiyolojik faktörler denir. TMEH'lerin etiyolojisi karmaşık ve multifaktöriyeldir. Kanıta dayalı literatür TMEH ile ilişkili beş ana faktör ortaya koymaktadır. Bunlar oklüzal faktörler, travma, duygusal stres, derin ağrı ve parafonksiyonel aktivitelerdir [3].

2.2.1 Temporomandibular eklem hastalıklarının sınıflaması

Temporomandibular eklem hastalıklarının sınıflandırılması yıllarca kafa karıştırıcı bir konu olmuştur. Konu hakkında çok fazla sınıflandırma yapılmıştır. Welden Bell [26] 1986 yılında bir sınıflandırma sunmuştur ve bu bozuklukları mantıksal olarak kategorize etmiştir. Amerikan Diş Hekimleri Birliği (ADA) bu sınıflandırmayı birkaç küçük değişiklikle benimsemiştir [27]. 2019'da Okeson kendi eklemeleriyle bazı değişiklikler yaparak bir sınıflandırma yayınlamıştır [3]. Amerikan Orofasiyal Ağrı Akademisi de kılavuzlarının son üç baskısı için benzer bir sınıflandırma benimsemiştir [2].

Bu sınıflandırma, tüm TMEH'yi klinik özelliklerine göre; çiğneme kası bozuklukları, TME bozuklukları, kronik mandibular hipomobilitate bozuklukları ve büyüme bozuklukları olarak dört geniş kategoriye ayırmaktadır (Tablo 2.1). Bu kategorilerin her biri de klinik farklılıklara göre alt gruplara ayrılır. Bu alt kategorilerin belirlenmesi ve net bir şekilde tanımlanması doğru tedavi için önemlidir [3].


Tablo 2.1 Okeson'un TMEH sınıflaması [3]

A. Çiğneme Kaslarıyla İlgili Rahatsızlıklar	C. Kronik Mandibular Hipomobilité
1. Koruyucu kas kontraksiyonu 2. Lokal kas ağrısı 3. Miyofasiyal ağrı 4. Miyospazm 5. Santral aracılı miyalji	1. Ankiloz ▪ Fibröz ▪ Kemiksel 2. Kas kontraktürü ▪ Miyostatik ▪ Miyofibrotik 3. Koronoid empedans
B. Temporomandibular Eklem Rahatsızlıkları	D. Gelişimsel Rahatsızlıklar
1. Kondil–disk kompleksindeki düzensizlikler ▪ Disk deplasmanı ▪ Aralıklı kilitlenme ile disk deplasmanı ▪ Redüksiyonsuz disk deplasmanı 2. Eklem yüzeylerinin yapısal uyumsuzluğu ▪ Şekil değişiklikleri ➤ Diskte ➤ Kondilde ➤ Fossada ▪ Adezyonlar ➤ Disk-kondil arasında ➤ Disk-fossa arasında ▪ Sublüksasyon (Hipermobilité) ▪ Spontan dislokasyon 3. TME'nin inflamatuvar hastalıkları ▪ Sinovit / kapsülit ▪ Retrodiskit ▪ Artritler ➤ Osteoartrit ➤ Osteoartroz ➤ Poliartritis 4. İlişkili yapıların inflamatuvar bozuklukları ▪ Temporal tendinitis ▪ Stylomandibular ligament inflamasyonu	1. Konjenital ve gelişimsel kemik rahatsızlıkları ▪ Agenezis ▪ Hipoplazi ▪ Hiperplazi ▪ Neoplazi 2. Konjenital ve gelişimsel kas rahatsızlıkları ▪ Hipotrofi ▪ Hipertrofi ▪ Neoplazi

2.2.2 Kondil–disk kompleksindeki düzensizlikler

Kondil-disk kompleksindeki düzensizlikler, diskin kondil üzerindeki hareketi esnasında normal konumunun bozulmasından kaynaklanır. Diskin hareketindeki bu bozukluk, diskal kollateral ligamentlerin ve inferior retrodiskal laminanın uzaması, diskin posterior sınırının incilmesi gibi durumlarda meydana gelebilir. Lubrikasyonun bozulması da disk deplasmanlarının olası bir etiyolojik faktörü olarak öne sürülmektedir [2, 3]. Kondil-disk kompleksinin bozulmasıyla en sık ilişkilendirilen etiyolojik faktör travmadır. TME'de meydana gelen travma, yoğunluk derecesine göre makrotravma ve mikrotravma olarak sınıflandırılabilir. Mandibular fraktürü içeren fasiyal kırık, TME makrotravmasının ana tipidir. Maloklüzyon ve tek taraflı çığnemenin yanı sıra bruksizm, diş gıcırdatma gibi parafonksiyonel alışkanlıklar TME mikrotravması kategorisine dahildir [28]. TME hareketi sırasında LPK'nın uygunsuz aktivitesi de disk düzensizliği ile ilişkilendirilmiştir. Redüksiyonsuz anterior disk deplasmanı olan hastalarda LPK'da hipertrofi, atrofi ve kontraktür gibi morfolojik değişiklikler bulunmuştur [29]. LPK'nın diske bağlandığı ancak kondile bağlanmadığı kişilerde anterior disk yer değiştirmesine karşı daha yüksek bir eğilim bulunmuştur [30].

Diskin normal pozisyonunda; ağız kapalı konumdayken diskin posterior bandı, kondilin üstünde yaklaşık olarak saat 12 (± 10 derece) hizasında, intermediate zon ise kondilin anterior kısmı ile artiküler eminensin posterior kısmı arasında konumlanmaktadır [31-34] (Şekil 2.15).




Şekil 2.15: Normal disk pozisyonu [35].

Kondil-disk kompleksindeki düzensizlikler arasında en sık görülen diskin anteriora deplase olmasıdır [2, 3, 36]. Medial ya da lateral yönde deplasman nadirdir. Antero-lateral deplasman, lateral disk bağlantısının zayıflığıyla ilişkili olarak, ikinci en yaygın kayma türü olarak bulunmuştur [36].

2.2.2.1 Redüksiyonlu disk deplasmanı

Redüksiyonlu disk deplasmanı (RDD) kondil-disk kompleksini içeren intrakapsüler biyomekanik bir bozukluktur. Kapalı ağız pozisyonunda, disk kondile göre anterior pozisyonundadır. Ağız açıldığında, anteriora konumlanmış olan disk kondille normal anatomik ilişkisine geri dönmektedir (Şekil 2.16). Diskte mediale ve laterale yer değiştirme de mevcut olabilir [2, 3, 37].



Şekil 2.16: Normal disk pozisyonu ve redüksiyonlu disk deplasmanı [38].

Redüksiyonlu disk deplasmanında, sadece ağız açılırken klik sesi veya ağız hem açılırken hem de kapanırken klik sesi (resiprokal klik) hissedilebilir. Resiprokal klik mevcut olduğunda, iki klik genellikle farklı açılma derecelerinde meydana gelmektedir. Açılma kliği, disk yer değiştirmesi miktarına, diskin anatomisine ve hareket hızına bağlı olarak hareketin herhangi bir yerinde oluşabilir. Kapanma kliği ise etkileyen faktör olan süperior LPK'nın, diski bir kez daha yer değiştirmeye zorlamasıyla, interküspal pozisyonun çok yakınında meydana gelir. Mandibula

açılırken, klik sesi gelene kadar etkilenen tarafa doğru sapar ve diskin yakalanmasının ardından orta hatta geri döner [3, 39].

Redüksiyonlu disk deplasmanı, hem ağız açma hem de eksantrik hareketler sırasında çenenin hareket aralığının normal olması ile karakterizedir. Hareket aralığında var olan herhangi bir kısıtlama, gerçek bir yapısal disfonksiyondan ziyade ağrı nedeniyle olmaktadır. Çoğu zaman ağrı mevcut olmasa da ağrı görülebilir ve bu ağrı doğrudan eklem fonksiyonu ile ilişkilidir [3].

2.2.2.2 Aralıklı kilitlenme ile birlikte redüksiyonlu disk deplasmanı

Kapalı ağız pozisyonunda, disk kondile göre anterior pozisyonundadır ve ağız açıldığında disk aralıklı olarak redükte olmaktadır. Disk ağız açılırken redükte olamazsa, aralıklı olarak ağız açıklığında kısıtlılık meydana gelir. Kısıtlı açılma olduğunda, kilitlenmeyi açmak için bir manevra gerekebilir. Diskin yerine oturmasıyla birlikte klik veya popping sesleri oluşabilir. Disk redükte olduktan sonra, açılma yolunda belirgin bir sapma görülür ve mandibular hareket aralığı normale döner [2, 37].

2.2.2.3 Redüksiyonsuz disk deplasmanı

Redüksiyonsuz disk deplasmanı (RSDD), kondil-disk kompleksini içeren intrakapsüler biyomekanik bir bozukluktur (Şekil 2.17). Ligamentin daha fazla uzaması ve süperior retrodiskal laminanın elastikiyetinin kaybolmasıyla, kondilin diski yeniden yakalaması daha da zor hale gelir. Kapalı ağız pozisyonunda, disk kondile göre anterior pozisyonundadır ve ağız açıldığında da disk redükte olmamaktadır. Diskin mediale ve laterale deplasmanı da mevcut olabilir [3, 37].

Redüksiyonsuz disk deplasmanında, hasta veya hekimin manipülatif bir manevra yapmasıyla düzelmeyen ve yemek yemeyi engelleyecek kadar ciddi olan, kısıtlı mandibular açıklık mevcuttur. Bu durum kapalı kilitlenme olarak tanımlanmaktadır. Ağız açıklığının maksimum aralığı 25-30 mm olup [3], hasta daha geniş açmaya çalıştığında mandibula ilgili eklem tarafına sapma gösterir. Eksantrik hareketler ipsilateral tarafa doğru nispeten normalken kontralateral tarafa doğru sınırlıdır. RSDD'de ağrı olabilir ve genellikle çeneyi eklem takıldığı noktanın ötesinde açmaya çalışırken ortaya çıkar. Hastalardan alınan anamnez kilitlenmeden

önce klik sesinin olduğunu ancak RSDD meydana geldikten sonra bu sesin kaybolduğunu göstermektedir [2, 37].

Bu tanımlanan bulgular RSDD akut durumda olduğunda yaygındır. Ancak durum kronik hale geldiğinde klinik tablonun netliği azalır. Bunun nedeni, ligamentlerin sürekli olarak uygulanan kuvvetlere karşı zamanla uzamasıdır. Bu uzama, çene hareketinde daha geniş bir aralık sağlayarak ayırıcı tanıyı zorlaştırır [3].



Şekil 2.17: Redüksiyonsuz disk deplasmanı [38].

2.3 TME Görüntüleme

Temporomandibular eklem hastalıklarında anamnez ve klinik muayene yeterli olmadığında uygun radyografik görüntüleme yöntemlerine başvurmak doğru teşhis ve tedavi açısından önemlidir. TMEH'nin teşhisinde kullanılan radyografik yöntemler: direkt grafiler, panoramik radyografi, bilgisayarlı tomografi (BT), konik ışınlı bilgisayarlı tomografi (KIBT), artrografi, ultrasonografi (USG) ve MRG'dir [4].

Kullanılacak görüntüleme tekniğinin türünü seçerken, ele alınacak spesifik klinik problem de dahil olmak üzere çeşitli değişkenler göz önünde bulundurulmalıdır. Bunlar arasında sert veya yumuşak dokuların görüntülenmesinin istenip istenmediği, kullanılacak tekniğin güçlü yönleri ve sınırlılıkları, incelemenin maliyeti ve radyasyon dozu yer almaktadır [40].

2.3.1 Direkt radyografiler

Direkt radyografiler, sabit bir x ışını kaynağı ve bir film kullanılarak oluşturulan iki boyutlu (2D) görüntüleme yöntemleridir. Yalnızca TME'ye ait kemik yapıların görüntülenebildiği, bu yapılara ait patolojilerin ve bu yapıların birbiriyle

ilişkisinin incelenmesinde kullanılan; kırık ve yumuşak dokuların ise görüntülenemediği yöntemlerdir. Direkt radyografiler, kaba dejeneratif veya travmatik kemik değişikliklerinin tespit edilmesine olanak sağlasa da bölgenin anatomisi, süperpozisyon ve geometrik distorsiyon nedeniyle kullanımları sınırlıdır. Lateral oblik transkraniyal, transmaksiller, transfarineal, transorbital, submentovertikal, reverse towne, posterior-anterior, lateral ve posteroanterior sefalometrik direkt radyografi yöntemleridir [41, 42].

2.3.1.1 Lateral oblik transkraniyal radyografi

Direkt radyografide en sık kullanılan yöntemdir. Lateral oblik transkraniyal görüntüleme yönteminde hasta başı infraorbital hat yere paralel, sagittal hat yere dik olacak şekilde pozisyonlandırılır. Film kaseti, görüntülenmek istenen kondil tarafında sagittal hatta paralel olacak şekilde yerleştirilir. X-ışınları, karşı taraf dış kulak yolunun 3-5 cm üstünden ve 1,5 cm arkasından 25° açı ile görüntülenecek kondil başından geçecek şekilde yönlendirilir. Bu teknikte kondil başı ve glenoid fossa sınırları, kondilin lateral kısmı ve artiküler eminensin lateral görüntüsü elde edilir [5].

Ağız açık ve kapalı konumda olacak şekilde iki farklı görüntüleme yapılabilir. Ağız açık konumda, kondil başının artiküler eminensle ilişkisi gözlemlenirken, ağız kapalı konumda eklem boşluğu ile kondil başının ilişkisi değerlendirilir. Bu yöntem, eklem lateral sınırını, kondil fraktürlerini ve büyük artritik değişiklikleri göstermede etkili olsa da minimal düzeydeki kemik değişikliklerini gösterme konusunda yetersizdir. Kondilin sadece lateral bölgesinin görüntülenmesi dezavantajı olsa da eklem patolojilerinin sıklıkla bu bölgede görülmesi durumu tolere etmektedir [5, 41, 43].

2.3.1.2 Transmaksiller radyografi

Hastanın ağızı açıkken merkezi ışının kondilin uzun eksenine dik olarak gönderildiği, anteroposterior görüntüleme tekniğidir. Bu görüntü transkraniyal projeksiyonu tamamlayarak, fraktür, neoplazm, anomali ve şiddetli dejeneratif eklem hastalığı açısından eklem 2D olarak daha detaylı değerlendirmesine olanak tanır. Kondil boynu kırıkları genellikle kondil başının mediale yer değiştirmesiyle sonuçlandığından bu radyografin kullanımı özellikle travma hastalarında yararlı olmaktadır [41].

2.3.1.3 Transfarengeal radyografi

Transfarengeal radyografide kaset, görüntülenmek istenen kondil tarafına, hastanın sagittal hattına paralel olacak şekilde yerleştirilir. Hastanın başı dik ve ağız açık konumdayken x ışınları, karşı taraftaki sigmoid çentikten aşağıdan yukarıya ve önden arkaya doğru yaklaşık 5-10° açıyla, görüntüsü istenen kondil başından çıkacak şekilde yönlendirilir. Bu teknik özellikle kondil boynu fraktürlerini görmek için kullanılmaktadır [5, 41].

2.3.1.4 Transorbital radyografi

Transorbital radyografide hastanın başı, orbitameatal hat yere paralel olacak şekilde konumlandırılır. Kaset hastanın omzu üzerinde, yere dik olarak yerleştirilir ve hastadan ağzını maksimum açması istenir. X ışınları karşı taraf orbitadan görüntülenmesi istenen TME'ye doğru yönlendirilir. Bu teknik kullanılarak, kondil başının ve boynunun görüntüsü alınabilir. Özellikle kondil boynu fraktürleri ve kondil başının dejeneratif değişikliklerinin incelenmesinde tercih edilen bir yöntemdir [5, 45].

2.3.1.5 Submentoverteks radyografi

Submentoverteks radyografi tekniğinde, x ışını ramusun posterior sınırına paralel olarak kafa kaidesine doğru yönlendirilir. Zigomatik ark fraktürlerinin değerlendirilmesinde kullanılan bir görüntüleme yöntemidir. Fasiyal asimetri, mandibular kondil asimetrisi, hiperplazi ve hipoplazi gibi durumların görüntülenmesi için kullanılabilir. Ayrıca travma veya ortognatik cerrahi sonrası kondil deplasmanları ve rotasyonlarının tespitinde faydalıdır [41, 46].

2.3.1.6 Reverse towne radyografi

Görüntü reseptörü, hastanın önüne, midsagittal düzleme dik ve koronal düzleme paralel olarak yerleştirilir. Kantomeatal düzlem reseptörle 30° lik bir açı oluşturacak şekilde hastanın başı öne eğilir. Kondillerin daha iyi görüntülenmesi için, hastanın ağzı açtırılarak kondil başlarının artiküler eminensin altına yerleşmesi sağlanır. X ışınları, kondil seviyesini merkez alarak görüntü reseptörüne dik ve hastanın midsagittal düzlemine paralel olarak yönlendirilir. Bu prosedür, kondil ve

kondil boynunu içeren şüpheli kırık vakalarının değerlendirilmesinde kullanılmıştır [40].

2.3.1.7 Posteroanterior radyografi

Posteroanterior radyografide, görüntü reseptörü hastanın önüne, midsagittal düzleme dik ve koronal düzleme paralel olarak yerleştirilir. X ışınları posteriordan anteriora doğru midsagittal düzleme paralel olarak gönderilir. Bu teknik komşu kemik yapılar üzerinde süperpozisyon etkisi nedeniyle eklemlerle ilgili sınırlı bilgi sunar. Posteroanterior radyografi daha çok fasiyal asimetri gibi durumların takibi amacıyla kullanılmaktadır [47].

2.3.1.8 Lateral sefalometrik radyografi

Lateral sefalometrik radyografide baş sefalostatta sabitlenirken, reseptör sagittal düzleme paralel olarak yerleştirilir. X ışınları reseptöre dik olarak, meatus akustikus eksternus üzerinden yönlendirilir. Sefalometrik görüntüleme çoğunlukla ortodontik analizlerde kullanılmaktadır. Bu teknik komşu kemik yapılar üzerinde süperpozisyon etkisi nedeniyle eklemlerle ilgili sınırlı bilgi sunar [44].

2.3.2 Panoramik radyografi


Panoramik radyografi, diğer adıyla pantomografi, diş hekimleri tarafından yaygın olarak kullanılan bir görüntüleme yöntemidir ve ilk hasta değerlendirmelerinde kapsamlı bir klinik bakış açısı sağlamaktadır. Panoramik radyografi, maksiller ve mandibular dental arklar ile bu yapıların destek dokularını geniş, kavisli bir görüntü halinde sunan bir görüntüleme tekniğidir. Bu görüntü, x-ışını kaynağı ile görüntü alıcısının hastanın başı etrafında tek bir dönüş yapmasıyla elde edilir [40]. Bu yöntemle tek bir film üzerinde tüm dişler, maksilla, mandibula, maksiller bölgenin orbitanın üst 1/3'üne kadar olan kısmı, maksiller sinüsler ve TME bir arada izlenmektedir (Şekil 2.18). Bu da dişlerden ve diğer hastalıklardan kaynaklanabilecek problemlerin, TMEH semptomlarından ayrılmasını sağlar [40, 44].



Şekil 2.18: Panoramik radyografi.

Panoramik radyografi ile TME bölgesi karşılıklı olarak değerlendirilebilir ve TME'lerdeki çeşitli değişiklik ve patolojiler incelenebilir. Panoramik radyografilerde, TME bölgelerindeki erozyon, osteofit (kemik çıkıntıları), düzleşme gibi osteoartritik değişiklikler; fraktürler, boyut ve şekil anomalileri, dejeneratif ve inflamatuvar durumlar, maksiller tümörler, metastazlar ve ankiloz gibi kemik değişiklikleri değerlendirilebilir [4, 40, 45]. Ancak panoramik radyografinin bazı sınırlamaları mevcuttur. Panoramik radyografide ışınlar kondilin uzun aksına oblik şekilde geldiğinden, kondilin lateral ve merkezdeki kısımları gözlenebilir. Kondil morfolojisindeki farklılıklar nedeniyle panoramik radyografideki kondil görüntüsü distorsiyona uğramaktadır. Artiküler tüberkül ve fossa üzerine kafa tabanı ve zigomatik ark süperpoze olduğundan ancak belirgin yapısal değişiklikler teşhis edilebilir. Ayrıca, ağız hafifçe açık ve ileri doğru olduğundan kondil pozisyonu da değerlendirilemez [5, 44].

Bazı panoramik radyografi cihazlarının özel TME çekim programları bulunmaktadır. Her iki eklemin de ağız açık ve kapalı pozisyonda görüntüsünün tek bir film üzerinde gözlenebildiği bu radyografilere ağız açık-kapalı TME grafisi ya da lateral panoramik grafi denilmektedir [45] (Şekil 2.19).



Şekil 2.19: TME grafisinde ağız açık-kapalı pozisyonda kondil ve artiküler eminens [48].

a. Ağız kapalı pozisyonda sağ kondil ve artiküler eminens b. Ağız açık pozisyonda sağ kondil ve artiküler eminens c. Ağız açık pozisyonda sol kondil ve artiküler eminens d. Ağız kapalı pozisyonda sol kondil ve artiküler eminens

2.3.3 Konvansiyonel tomografi

Tomografi yönteminde, bir x ışın kaynağının ve bir filmin senkronize hareket etmesi ile görüntü oluşmaktadır. TME'nin, çevre anatomik dokuların süperpozisyonu olmadan çok sayıda ince kesitin elde edilebildiği yöntemdir [41].

Konvansiyonel tomografi ile kondile dik çok sayıda kesit elde edilebildiği için kondil ve çevre kemiklerdeki değişikliklerin belirlenmesinde direkt ve panoramik radyograflere göre üstündür. Yüksek maliyetli olması, yüksek radyasyon dozu, eklemin yumuşak dokularının görüntülenememesi ve teşhis için sağladığı bilginin sınırlı olması dezavantajlarıdır [41, 45].

2.3.4 Bilgisayarlı tomografi


Bilgisayarlı tomografide, vücudun çekim yapılan bölgesinden geçen x ışınlarının atenüasyon miktarları dedektörler tarafından ölçülmekte ve bilgisayarda görüntüye dönüştürülmektedir. BT ile incelenmek istenen yapılar aksiyal, sagittal ve koronal düzlemde ince kesitler halinde görüntülenebilir. Kesitsel görüntüler elde edildiği için, incelenen bölgenin detayları daha net ve ayrıntılı bir şekilde görülebilir. Ayrıca, BT ile orijinal verilerden 3 boyutlu (3D) rekonstrüktif görüntüler oluşturulabilir [40].

Yumuşak ve sert dokuların bir arada izlenebilmesi BT'nin en büyük avantajı olup ayrıca 3D görüntüleme, görüntü üzerinde ölçüm yapabilme ve hacim

oluşturabilme gibi avantajları da vardır. BT'nin kullanımı ile direkt filmlerde bulunan distorsiyon ve süperpozisyon; konvansiyonel tomografilerde ise imaj tabakası dışında kalan yapıların bulanıklaşması gibi dezavantajlar ortadan kalkmıştır. Hastanın aldığı yüksek radyasyon dozu, çekim işleminin uzun sürmesi, cihazın maliyetli olması ve yumuşak dokuyu ayırt edebilmedeki yetersizliği tekniğin dezavantajlarıdır [4, 40, 41].

Bilgisayarlı tomografi eklemde kemik bileşenlerinin 3D yapısı, eklem anatomisi (Şekil 2.20), eklemde fraktür ve patolojik değişiklikler hakkında detaylı bilgi verir. BT ile eklemdeki yumuşak dokular, ödem, hematoma gibi lezyonlar da değerlendirilebilir. Artiküler diskin redüksiyonlu ve redüksiyonsuz dislokasyonları görüntülenebilse de TME'nin yumuşak dokularının değerlendirilmesi için en çok kullanılan yöntem MRG'dir [5, 40, 41].

Günümüzde mekanik taramalı BT cihazları içinde en son teknoloji, Multislice Bilgisayarlı Tomografi (MSBT) teknolojisidir. MSBT'lerde dedektördeki halka sayısı arttığı için cihazın taradığı hacim artar ve görüntü kalitesi yükselir. Multidedektör BT olarak da adlandırılan bu teknoloji tarama sürelerini önemli ölçüde azaltmış ve daha yüksek çözünürlük, daha az radyasyon maruziyetiyle birlikte daha hassas görüntü elde edilmesini sağlamıştır [40, 42].



Şekil 2.20: BT sagittal görüntülerde TME'nin anatomisi, (a) kemik penceresi, (b) yumuşak doku penceresi[4].


2.3.5 Konik ışınli bilgisayarlı tomografi

Konik ışınli bilgisayarlı tomografi, maksillofasiyal bölgedeki kemik yapıların görüntülenmesi için geliştirilmiştir (Şekil 2.21). KIBT ile konvansiyonel BT'nin görüntüleme geometrisi farklıdır. BT'de x ışınları yelpaze şeklinde gönderilirken KIBT'da x ışınları konik olarak gönderilmektedir [45].

Konik ışınli bilgisayarlı tomografi cihazlarının birçoğunda sadece görüntülenmesi istenen bölge ışınlandığından hastaya verilen radyasyon dozu büyük ölçüde azalmaktadır. KIBT; çoklu rotasyonlar yerine, 360° lik tek bir rotasyon ile görüntü oluşturduğundan ışınlama süresi kısalmaktadır. Böylelikle hem hastanın aldığı radyasyon miktarı hem de hareket artefaktları azalır. KIBT ile görüntülemeye efektif doz (19-368 *mikroSievert* (μSv)) konvansiyonel BT'lere (1400-2100 μSv) oranla çok daha azdır [5, 49]. KIBT'da görüntü çözünürlüğü yaklaşık 2 *line pairs per millimeter* (lp/mm) olduğu için BT'ye oranla 4 kat daha fazla netlik sağlamaktadır [48].

Konik ışınli bilgisayarlı tomografi, kraniyofasiyal bölgedeki kemik yapıyı değerlendirmede etkilidir ancak yumuşak doku değerlendirmesinde yetersiz kalmaktadır. KIBT; kist ve tümörlerin boyutlarının ve anatomik yapılarla ilişkisinin belirlenmesinde, gömülü dişlerinin pozisyon ve lokalizasyonunun incelenmesinde, implantolojide alveoler kreterin değerlendirilmesinde, sinüslerin durumunun değerlendirilmesinde, dudak damak yarığı olan hastaların tedavi planlamasında, endodontide kök kanal morfolojisinin incelenmesinde ve kök kırıkları veya kök rezorpsiyonlarının tespit edilmesinde, periodontolojide kemik defektlerinin ve periodontal sert dokuların incelenmesinde kullanılmaktadır [4, 5, 40, 50-53].

Konik ışınli bilgisayarlı tomografi TME'de osteofit, erozyon, skleroz gibi kondiler kemik yapı değişikliklerinin ve fraktür, gelişimsel anomaliler, ankiloz gibi patolojilerin belirlenmesinde kullanılır. Ayrıca ağız açık ve kapalı durumda kondil pozisyonunun değerlendirilmesinde de kullanılabilir [4].



Şekil 2.21: KIBT parasagittal kesitte TME'nin radyolojik anatomisi [4].

2.3.6 Artrografi

Artrografi; floroskopik rehberlik ile lokal anestezi altında, alt ya da üst eklem boşluğuna veya her ikisine birden radyoopak kontrast madde enjekte edilerek diskin görüntülendiği, dinamik ve invaziv bir tekniktir [43]. Bu amaçla, iyot içeren kontrast maddeler kullanılır. Artrografi için gereken kontrast madde miktarı sınırlı olduğundan kontrast maddenin 300 mg iyot/mL gibi yüksek iyot konsantrasyonuna sahip olması önemlidir [4].

Disk perforasyonunu ve kapsül adezyonunu en iyi gösteren yöntem artrografidir [43]. Artrografide RDD ve RSDD, disk perforasyonu, erken dejeneratif eklem hastalığı ve sinovyal kondromatozis gibi patolojiler değerlendirilebilir. Bu yöntemin dezavantajları arasında; deneyim gerektirmesi, invaziv olması, eklem diskinin medial ve lateral deplasmanını göstermede yetersiz olması, işlem esnasında ve sonrasında ağrı oluşması, hastanın radyasyona maruz kalması, enfeksiyon ve kontrast maddeye karşı alerji riskinin olması bulunmaktadır. Bu dezavantajlar sebebiyle günümüzde MRG, artrografinin yerini almıştır [44, 48, 54].

2.3.7 Ultrasonografi

Sonografi, iyonize radyasyon kullanmadan ses dalgalarıyla gerçek zamanlı görüntü elde edilen bir tekniktir. Ultrason, duyulabilir frekansın üstünde, 20 kHz'in üzerindeki frekanslara sahip ses dalgalarını ifade eder. Tanısal ultrasonografide, 1-20 MHz frekans aralığındaki ses dalgaları kullanılmaktadır [40]. Sonografi cihazları, elektrik enerjisini ses enerjisine dönüştüren transdüsörler aracılığıyla ultra yüksek frekanslı ses dalgaları üretir. Bu ultrasonik ses dalgaları farklı akustik empedansa sahip dokulardan geçer veya onlarla etkileşime girer. Transdüser geri yansıyan ses dalgaları transdüser tarafından algılanır, işlenir ve dijital bir görüntüye dönüştürülür. Yüksek frekanslı ses dalgaları daha iyi çözünürlük sağlarken, yumuşak dokulara penetrasyonları daha düşüktür [40, 55]. USG invaziv olmayan, iyonize radyasyonun kullanılmadığı, maliyeti düşük, kolay uygulanabilen bir görüntüleme yöntemidir [5].

Ultrasonografi, baş ve boyun bölgesinde tiroid, paratiroid, tükürük bezleri, lenf düğümü neoplazmları, tükürük bezi taşları, Sjögren sendromu ve karotid arterdeki aterosklerotik plak gibi durumların değerlendirilmesinde kullanılır [40].

Temporomandibular eklem incelemesinde USG, disk deplasmanları, efüzyon, eklem içi defektlerin teşhisi ve tedavi sonuçlarının değerlendirilmesinde kullanılabilir [45]. TME görüntülenmesinde, yüksek frekanslı lineer probalar (tercihen 12 MHz'in üzerinde) kullanılır. Bu probalar düşük penetrasyon derinliği ile yüksek çözünürlükte görüntü sağlamaktadır [55]. USG'nin avantajı TME'nin sert ve yumuşak dokularının dinamik olarak görüntülenmesine olanak sağlamasıdır. USG'nin bu değerlendirmedeki en büyük sınırlılığı ise ses dalgalarının karşılaştığı sert dokular sebebiyle sapması ve anormal yansımasıdır [56].



Şekil 2.22: Kapalı ağız pozisyonunda USG’de artiküler disk ve kondilin görüntülenmesi [55].

2.3.8 Manyetik rezonans görüntüleme

Manyetik rezonans görüntülemeye, manyetik alan ve radyofrekans (RF) dalgaları kullanılarak 3D görüntü elde edilmektedir. Bir MR görüntüsü oluşturmak için, hasta öncelikle büyük bir manyetik alanın içine yerleştirilir. Bu manyetik alan, özellikle hidrojen atomu olmak üzere vücuttaki birçok atomun çekirdeklerinin manyetik alana uygun olarak hizalanmasını sağlar. RF enerjisi, görüntü alınacak bölgeye gönderilir ve bu da bazı hidrojen çekirdeklerinin enerjisiyi emmesine (rezonansa girmesine) neden olur. Sonrasında RF enerjisi kesilir ve hidrojen iyonları aldıkları enerjiyi geri vererek eski konumlarına dönerler. Bu süreçte hidrojen iyonlarının geri verdiği RF sinyalleri bir alıcı tarafından algılanır ve sinyal farklılıkları ile MR görüntüsü oluşturulur [5, 40].

Manyetik rezonans görüntülemeye, görüntülerdeki gri tonlar dokunun sinyal özelliklerine bağlı olarak değişiklik göstermektedir. Beyaz veya açık tonlar yüksek sinyal alanlarını (hiperintens alanları) temsil ederken, koyu veya siyah tonlar düşük ya da hiç sinyal almayan alanları (hipointens alanları) gösterir [5].

Manyetik alan içerisine konulan protonların net mıknatıslanması Z ekseninde ve dış manyetik alanla paralel olup buna longitudinal manyetizasyon denir. MR’da sinyal longitudinal manyetizasyon vektöründen elde edilir fakat aynı yönde dış manyetik alan bulunduğundan bu sinyal direkt olarak ölçülemez. Dokudan sinyal elde edebilmek için net manyetik vektörün Z ekseninden Y eksenine yön değiştirmesi gerekir. Bu amaçla RF dalgaları kullanılmaktadır. Gönderilen RF pulsu sonrasında net

manyetik vektörün Z ekseninden Y eksenine yön değiştirmesiyle transvers manyetizasyon oluşur [5].

Radyofrekans pulsu verildikten sonra longitudinal manyetizasyonun oluşması için geçen süre T1 relaksasyon zamanı olarak adlandırılır. Her dokunun T1 relaksasyon süresi farklıdır. T1 relaksasyon süresi kısa olan dokular T1 ağırlıklı görüntülemelerde hiperintens görünürler. T1 relaksasyon süresi uzun olan dokular ise hipointens olarak görünürler. Sıvılar uzun T1 süresine sahip olduğundan T1 ağırlıklı görüntülemelerde hipointens görüntü verirler. Daha büyük moleküller ise enerjilerini daha hızlı transfer ettiğinden bu dokuların T1 süresi kısadır. Yağ dokusu kısa T1 süresine sahip olduğundan T1 ağırlıklı görüntülemelerde hiperintens görüntü verir. RF pulsunun kesilmesiyle beraber transvers manyetizasyon azalmaya başlar. Transvers manyetizasyonun %37 seviyesine düşmesine kadar geçen süreye T2 relaksasyon zamanı denir. Sıvıların T2 süresi uzundur ve T2 ağırlıklı görüntülemelerde hiperintens görünürler. Kısa T2 süresine sahip dokular ise hipointens görünür [5].

T1 ağırlıklı görüntüler normal anatomik detayları değerlendirmede çok faydalıdır. T2 sekansı ise sıvı içeren dokuları ve patolojik sinyal yoğunluğundaki değişiklikleri değerlendirmek için kullanılmaktadır. Patolojik oluşumların incelenmesinde öncelikle T2 sekansında görüntüleme yapılsa da iyi bir değerlendirme için hem T1 hem de T2 sekansları kullanılmalıdır. Böylece her iki sekansta elde edilen görüntüler kıyaslanabilir [5].

Manyetik rezonans görüntüleme, yumuşak doku kontrastı en yüksek olan görüntüleme yöntemidir. Bu yöntemde iyonize radyasyon kullanılmamaktadır ve bilinen biyolojik bir hasar oluşturmamaktadır. Bu nedenle yöntem çocuklarda ve hamilelerde kullanılabilir ve aynı hastada tekrarlanabilir. Bu avantajlarının yanında her klinikte bulunmayışı, maliyetinin yüksek olması, görüntülerin oluşturulma ve yorumlanma sürelerinin uzun olması gibi dezavantajları da vardır. Güçlü manyetik alan, ferromanyetik metal (kalp-pili, bazı serebral anevrizma klipsleri gibi) bulunduran hastalarda güçlü bir elektrik akımına ve metalin aşırı ısınmasına yol açtığı için, bu hastalarda MRG kontrendikedir. Kapalı alan fobisi olan, sabit duramayan ve kooperasyon kurulamayan hastalarda da MRG kontrendikedir. Sabit ortodontik apareyleri ve metal protezleri olan kişilerde ise MRG kullanılabilir [5, 45, 48].

Manyetik rezonans görüntüleme, TME görüntülenmesinde altın standart olarak kabul edilmektedir [3-5, 47]. Ağız açık ve kapalı konumda iken diskin pozisyonu, disk morfolojisi ve diskteki patolojiler, retrodiskal dokular, kemik yapılar, çiğneme kasları, eklem inflamatuar hastalıkları ve bu hastalıkların yol açtığı yumuşak doku değişiklikleri, postoperatif değişiklikler MRG ile belirlenebilir. Ancak MRG'nin; erken dejeneratif kemik değişiklikleri, disk adezyonları ve perforasyonları hakkında verdiği bilgiler yeterli olmayabilir. Artiküler disk adezyonları ve perforasyonlarında artrografi daha iyi sonuç vermektedir [5, 48].

Temporomandibular eklemi görüntülemek için standart MRG protokolleri, intraartiküler yapıları ve disk pozisyonunu değerlendirmek amacıyla kapalı ve maksimum açık ağız pozisyonunda proton ağırlıklı ve/veya T2 ağırlıklı sagittal oblik kesitler ile kapalı ağız pozisyonunda koronal ve aksiyal kesitleri içerir. TME'nin genel anatomisini, kemik iliğini ve bitişik yumuşak dokuları değerlendirmek, ayrıca diğer bitişik patolojileri dışlamak amacıyla kapalı ağız koronal ve aksiyal T1 sekanslarına ihtiyaç duyulur. Yağ baskılamalı ve T2 ağırlıklı görüntüler, eklem efüzyonunu tespit etmeye ve T1 ile birlikte kemik iliği ödemi değerlendirilmeye yardımcı olur [57].

2.4 Yapay Zekâ Nedir?

Yapay zekâ, algılama, öğrenme, düşünme, kavramları ilişkilendirme, akıl yürütme, iletişim kurma, problem çözme, çıkarım yapma ve karar verme gibi insan zekâsına özgü yüksek bilişsel fonksiyonları gerçekleştirebilen bilgisayar sistemlerinin teorisi ve geliştirilmesi için kullanılan genel bir terimdir [58].

2.4.1 Yapay zekânın tarihçesi


Yapay zekânın temeli olarak kabul edilen ilk çalışma, 1950 yılında Alan Turing'in yazdığı ve *The Mind* dergisinde yayınlanan "Hesaplama Makineleri ve Zekâ" başlıklı makaledir [59]. Bu çalışmada Turing, "Makineler düşünebilir mi?" sorusunu sormuş ve bu soruya yanıt verebilmek için Turing testini önermiştir. Turing testi esasen iki insan ve bir bilgisayar arasında gerçekleşen bir oyun olarak tanımlanabilir. Değerlendirici olan insan, diğer iki oyuncuya (biri insan, biri bilgisayar) açık uçlu sorular sorarak hangisinin insan olduğunu belirlemeye çalışır. Değerlendirici bir sonuca varamazsa, bilgisayarın zeki olduğu kabul edilir.

Bu test ile yapay zekâ tarafından oluşturulan bir sistemin insan zekâ seviyesine ulaşp ulaşmadığını belirleyerek, makinenin öğrenme ve düşünme yeteneği değerlendirilir [59, 60].

1956 yılında yapılan Dartmouth Konferansı yapay zekâ teriminin resmen kullanıldığı yer olarak kabul edilir [61]. Konferans, zekâ tüm yönleriyle kesin bir şekilde tanımlanabilirse zekayı simüle edebilecek bir makinenin yapılabileceği varsayımı ile ilerlemiştir. Konferansta makinelerin dili nasıl kullanacakları, kavramları nasıl oluşturacakları, insana özgü sorunları nasıl çözecekleri ve kendilerini nasıl geliştirecekleri bulunmaya çalışılmıştır [62].

2.4.2 Makine öğrenmesi

Bir veri kümesine ve bu veriler hakkında bazı bilgilere dayalı olarak, eğitim verilerinden öğrenebilen ve öğrendiklerini uygulayarak tahminde bulunabilen algoritma sistemidir. Makine öğrenimi, örneklerden anlamlı sonuçlar çıkarma yeteneği sağladığı için yapay zekanın bir dalı olarak kabul edilir (Şekil 2.23). Makine öğreniminin amacı, makinelerin veri üzerinden öğrenmesini sağlayarak insan müdahalesi olmadan sorunların çözülmesini kolaylaştırmaktır [63, 64]. Makine öğrenimi, denetimli, denetimsiz ve pekiştirmeli öğrenme olmak üzere geniş kategorilere ayrılır [65].



Şekil 2.23: Yapay zekâdan derin öğrenmeye temel kavramlar.

2.4.2.1 Denetimli öğrenme

En yaygın kullanılan öğrenme stratejisidir. Denetimli öğrenme, elle etiketlenmiş eğitim verilerinden türetilen fonksiyonla, hesaplamaları gerçekleştirerek ve ardından hataları düzelterek beklenen çıktıyı elde etme anlamına gelir. Bir başka deyişle, bu sistemler el ile etiketlenmiş görüntüleri analiz ederek normal ve anormal özellikleri tespit etmeyi öğrenirler. Bu programlar genellikle iki türdedir:

1. Sınıflandırma: Çıktı değişkeni siyah veya beyaz gibi bir kategori, hastalık veya hastalık olmama gibi iki olası çıktıdan biridir.
2. Regresyon: Çıktı değişkeninin gerçek veya sürekli bir değer (ağırlık, fiyat veya boyut gibi) olduğu durumdur [58, 66].

2.4.2.2 Denetimsiz öğrenme

Denetimsiz öğrenme, girdilere dayalı olarak kendi başına çalışan bir makine öğrenimi yöntemidir. Öğreniciye belirtilen veriler etiketlenmemiştir ve farklı kümelere ayrılır; bu nedenle, bu modeller kümeleme algoritmaları olarak da bilinir. Ana sınırlama, çıktıların doğruluğunun açıkça değerlendirilmemesi olup, bu durum onu denetimli öğrenmeden ayırır [66].

2.4.2.3 Pekiştirmeli öğrenme


Pekiştirmeli makine öğreniminde, sistem verilerle etkileşime girer ve bu etkileşimler sonucunda hataları ve doğruları öğrenerek kendini geliştirir. Pekiştirmeli öğrenmenin temel unsuru deneme yanılma ve ödül mekanizmasıdır. Bu teknoloji, makinelerin ve yazılım araçlarının verimliliklerini artırmak amacıyla belirli bir durumda en iyi davranışı otomatik olarak seçmelerine olanak tanır [58].

2.4.3 Yapay sinir ağları

Yapay sinir ağları (YSA), insan beyninin işleyişini modelleyerek örnekler aracılığıyla öğrenme yeteneğine sahip, bu öğrendiği bilgileri kullanarak yeni bilgiler türetebilen ve keşif yapabilen sistemlerdir. Bu süreçte elde ettikleri bilgi, birikim ve tecrübeler sayesinde, çevreden gelen uyarılara insanlara benzer tepkiler verebilirler. Örneklerden edindikleri verilerle kendi deneyimlerini oluşturur ve benzer durumlarda karar verebilirler [67, 68].

Yapay sinir ağıları, insan zekasını modellemek için temel sinir hücrelerini yani nöronları örnek almaktadır. Her bir nöron; hücre gövdesi, dendrit ve akson adı verilen bileşenlerden oluşur. Dendritler bilgiyi diğer sinir hücrelerinden alıp hücre gövdesine iletir. Aksonlar ise çekirdekten gelen toplanmış sinyalleri diğer sinir hücrelerine aktarmakla görevli yapılardır. Nöronlar arasında öğrenmeyi sağlayan sinaptik bağlantılar bulunmaktadır. İnsanlar doğdukları andan itibaren sürekli olarak yeni şeyler öğrenirler ve bu süreçte nöronlar arasında yeni bağlantılar oluşur [67, 69].

Yapay sinir hücreleri, doğal nöronun yapısını ve davranışlarını kopyalayarak farklı kaynaklardan gelen birçok girdiyi alır ve bu girdileri işleyerek tek bir çıktı üretir. Yapay sinir hücreleri mühendislik disiplinlerinde proses elemanları olarak da tanımlanmaktadır. Her bir proses elemanı beş temel unsurdan oluşmakta olup bu unsurlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılarıdır [68] (Şekil 2.24).



Şekil 2.24: Yapay sinir hücresinin yapısı [70].

Girdiler ($x_1, x_2, \dots, x_n$): Yapay sinir hücresine diğer sinir hücrelerinden veya dış dünyadan gelen bilgilerdir.

Ağırlıklar ($w_1, w_2, \dots, w_n$): Girdilerin, hücre tarafından ne kadar dikkate alınacağını belirleyen faktörlerdir.

Toplama Fonksiyonu: Bir hücrenin net girdisini hesaplamak amacıyla kullanılan fonksiyondur.

Aktivasyon Fonksiyonu: Hücrenin net girdi değerine karşılık üretilecek çıktı değerini belirleyen fonksiyondur.

Çıktı (y): Aktivasyon fonksiyonu ile belirlenen çıktı değeridir. Bu çıktı, başka bir hücreye veya dış dünyaya iletilir [68].

Yapay sinir ağları, üç temel katmanın bir araya gelmesiyle oluşur. Bu katmanlar; girdi katmanı, gizli katmanlar (ara katmanlar) ve çıktı katmanıdır. Girdi katmanındaki proses elemanları dış dünyadan bilgileri alarak ara katmanlara iletirler. Ara katmanlar, girdi katmanından gelen verileri işleyerek çıktı katmanına gönderirler. Ara katman birden fazla katmandan oluşabilir, bu da YSA'nın derinliğini artırır ve daha karmaşık bilgileri işlemesini sağlar. Çıktı katmanı ara katmandan gelen bilgileri işleyerek ürettiği çıktıyı dış dünyaya iletir [67-69].

2.4.3.1 Yapay sinir ağı modelleri

Yapay sinir ağı modelleri; tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli YSA ve geri beslemeli YSA olarak dört grupta incelenebilir [69].

1.Tek katmanlı algılayıcılar: Bu ağlar yalnızca bir girdi ve bir çıktı katmanından oluşur. Doğrusal ilişkileri ve basit problemleri çözme kapasitesine sahip olmalarına rağmen, karmaşık problemleri çözmede ve doğrusal olmayan ilişkileri öğrenmede yetersizdirler [69].

2.Çok katmanlı algılayıcılar: Bu YSA modelleri, giriş ve çıkış katmanları arasında en az bir gizli katman barındırır. Tek katmanlı algılayıcılardan farklı olarak, doğrusal olmayan problemleri çözebilirler. Bu nedenle en yaygın kullanılan YSA modelleridir [71].

3.İleri beslemeli YSA: Bu ağlarda nöronlar, girişten çıkışa doğru düzenli katmanlar halinde yer alır. Her bir katman, yalnızca kendisinden sonraki katmanlara bağlanır. Girişe gelen bilgiler, doğrudan gizli katmana iletilir ve burada işlendikten sonra çıkış katmanına geçerek dış ortama aktarılır [72].

4.Geri beslemeli YSA: İleri beslemeli ağlardan farklı olarak, bir nöronun çıktısı sadece kendisinden sonraki katmana değil, önceki katmanlardaki veya kendi katmanındaki nöronlara da girdi olarak bağlanabilir. Bu yapı, geri beslemeli YSA'larına doğrusal olmayan dinamik bir davranış kazandırır. Geri besleme özelliği

kazandıran bağlantıların düzenine bağlı olarak, aynı YSA farklı davranışlar ve yapılar sergileyebilir [72].

2.4.3.2 Yapay sinir ağı kullanım alanları

Yapay sinir ağı; tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme gibi çeşitli alanlarda kullanılır [68, 73].

Tahmin: YSA, belirli girdi değerlerini kullanarak bir çıktıyı tahmin etme yeteneğine sahiptir. Örneğin, döviz kuru tahmini bu yöntemin bir uygulamasıdır [73, 74].

Sınıflandırma: Bu ağlar, belirli girdi değerlerini sınıflandırma görevinde kullanılır. Bir makinede ortaya çıkan hataların sınıflandırılması, bu tür bir uygulamaya örnektir [73, 74].

Veri ilişkilendirme: YSA, öğrenilmiş bilgileri kullanarak eksik verileri tamamlayabilir. Eksik bir resmin tamamlanması bu işleve örnek olarak verilebilir [73, 74].

Veri yorumlama: Bu ağlar, girdileri analiz ederek yeni olayların yorumlanmasını sağlar. Bir olay hakkında toplanan örneklerden elde edilen bilgiler ve eğitim sonucu oluşturulan veriler kullanılarak, yeni olayların değerlendirilmesi mümkündür [73, 74].

Veri filtreleme: Bu ağlar, geniş veri setleri içerisinde uygun verileri belirleme işlevini yerine getirir [73, 74].

2.4.4 Derin öğrenme

Derin öğrenme, YSA ile ilgili 1980'lerde yapılan araştırmalarda ortaya çıkan, makine öğreniminin bir alt dalıdır [65]. Derin öğrenme, gizli katmanların sayısının artırıldığı ve her katmanda probleme dair bir özniteliğin öğrenildiği, YSA'dan oluşan yöntemler bütünüdür. Bu mimaride her bir katmanda, soruna özgü bir öznitelik öğrenilir ve bu öznitelikler bir üst katmana iletilir, böylece en alt katmandan en üst katmana doğru karmaşıklık artarak ilerler [75].

Son yıllarda derin öğrenme yöntemlerine olan ilgi, bu tekniklerin doğrusal olmayan özellik çıkarımı yapabilme, hızlı işlem gerçekleştirme, kendi kendine

öğrenme ve genelleme kabiliyetleri sayesinde büyük ölçüde artmıştır. Derin öğrenme mimarileri, geleneksel yöntemlere kıyasla daha az bellek kullanarak, daha yüksek işlem hızı ve verimlilik sağlamaktadır. Bu nedenle, derin öğrenme teknikleri ile görüntü işleme, ses tanıma, doğal dil işleme ve daha pek çok alanda büyük ilerlemeler kaydedilmiştir [76].

Farklı alanlardaki veya farklı kullanım durumlarındaki problemleri çözmek için derin öğrenme mimarileri geliştirilmiştir. Örneğin, CNN genellikle görüntü işleme için kullanılırken, tekrarlayan sinir ağları-*recurrent neural network* (RNN) yaygın olarak zaman serisi verileri gibi sıralı verilerle çalışmak için geliştirilmiştir. Diğer yandan, sınıflandırma gibi genel problemler için kullanılan net bir mimari yoktur çünkü mimari seçimi birden fazla faktöre bağlı olabilir. Derin sinir ağlarında en yaygın kullanılan mimariler;

1. Konvolüsyonel Sinir Ağları (CNN)
2. Tekrarlayan sinir ağları (RNN)
3. Otomatik Kodlayıcı (Autoencoder)
4. Kısıtlı Boltzmann Makinesi (RBM)
5. Uzun Kısa Süreli Bellek (LSTM)' dir [77].

2.4.5 Konvolüsyonel sinir ağları


Konvolüsyonel sinir ağları, derin öğrenme yöntemleri arasında en ünlü olan ve en yaygın kullanılan algoritmalarlardır. CNN'in önceki yöntemlere kıyasla en büyük avantajı, öznetelikleri insan müdahalesi olmadan otomatik olarak tanımlamasıdır. CNN, bilgisayarla görme, konuşma işleme ve yüz tanıma gibi çeşitli alanlarda geniş çapta kullanılmaktadır. CNN'in yapısı, geleneksel bir sinir ağına benzer şekilde, insan ve hayvan beyinlerindeki nöronlardan ilham alarak tasarlanmıştır[78]. Daha spesifik olarak, bir kedinin beyninde görsel korteksi oluşturan karmaşık hücre dizisi, CNN tarafından simüle edilmiştir [79].

Konvolüsyonel sinir ağları, görüntünün piksel değerlerinden elde edilmiş matrise belirli katmanlarda konvolüsyon işlemi uygulanarak başlar. Bu işlem, kullanılan filtre türüne bağlı olarak ilk aşamalarda düşük seviyeli, daha sonraki

aşamalarda ise orta ve yüksek seviyeli öz niteliklerin çıkarılmasını sağlar. İlk katmanlarda düşük seviyeli öz nitelikleri öğrenen model, bu öz niteliklerden en baskın olanları sonraki katmanlara aktarır [80].

Konvolüsyonel sinir ağları, temel olarak şu katmanlardan oluşur: konvolüsyon, havuzlama, düzeltilmiş doğrusal birimler (*Rectified Linear Unit-RELU*), düzleştirme (*Flattening*) ve tam bağlı katmanlar (*Fully Connected Layer-FC*). Ayrıca, nöronları benzerliklerine göre saf dışı bırakan seyreltme (*Dropout*) yöntemi ve genellikle YSA'nın aktivasyon fonksiyonu olarak kullanılan softmax aşaması da bulunur [80].

Konvolüsyonel sinir ağları, şu anda tıbbi görüntülemelerde en yaygın kullanılan derin öğrenme mimarisidir [81, 82]. Radyoloji alanında CNN'ler sınıflandırma, tespit ve segmentasyon için kullanılır [65] (Şekil 2.25). Sınıflandırma, bir hastalığın varlığını veya yokluğunu belirlemekten, malignite türünü tanımlamaya kadar geniş skaladaki görevleri içerir [65, 83]. Bilgi işlem gücündeki ilerlemelerle birlikte, radyografik görüntü analizinde sınıflandırma problemlerini çözmek için daha derin ve daha karmaşık CNN modelleri geliştirilmiştir. Tespit, radyografik görüntülerde lezyonlar veya belirli anatomik yapılar içeren bölgeleri tanımlamayı ve yerini belirlemeyi içerir [65, 84]. Tespit görevleri için kullanılan CNN'ler, temelde sınıflandırma için kullanılanlarla benzerdir, ancak hastalık tespiti için bölge önerileri veya regresyon gibi ek işlemlere sahip birkaç katman içerir. Segmentasyon, direkt radyografi, BT, MRG ve USG gibi modaliteler kullanılarak elde edilen görüntülerde çeşitli anatomik yapıları veya lezyonları ayırt etmek için kullanılır [65, 83, 85].



Şekil 2.25: CNN’ler ile sınıflandırma, tespit ve segmentasyonun diş çürüğü örneği üzerinden gösterilmesi [86].

2.4.5.1 Konvolüsyonel sinir ağını oluşturan katmanlar

Giriş Katmanı: Bu katman CNN’in ilk katmanını oluşturur ve bu katmanda veri ham olarak ağı verilmektedir. Tasarlanacak modelin başarısı için bu katmandaki verinin boyutu büyük önem taşır. Giriş görüntü boyutunun yüksek seçilmesi yüksek bellek gereksinimine, uzun eğitim sürelerine ve görüntü başına düşen test süresinin uzamasına neden olabilir ancak bu durum ağın performansını artıracaktır. Görüntü analizinde, ağı derinliği, donanımsal hesaplama maliyeti ve ağı başarısı dikkate alınarak uygun bir giriş görüntü boyutu seçilmelidir [87].

Konvolüsyon Katmanı: CNN’in temelini oluşturan dönüşüm katmanı, belirli bir filtrenin tüm görüntü üzerinde dolaştırılması işlemine dayanır. 2x2, 3x3, 5x5 gibi farklı boyutlarda olabilen filtreler, bir önceki katmandan gelen görüntülere konvolüsyon işlemini uygulayarak çıkış verisini oluştururlar. Bu konvolüsyon işlemi sonucu aktivasyon haritası (öznitelik haritası) oluşur. Bu harita, filtre tarafından tespit edilen özelliklerin yoğunluğunu ve konumunu gösterir. Aktivasyon haritası ile görüntüdeki önemli özellikler tanınarak sonraki katmanlara aktarılır. Bu sayede, model daha karmaşık ve yüksek seviyeli özellikleri öğrenebilir [87].

Aktivasyon Katmanı: Aktivasyon katmanı ağı karmaşık ve doğrusal olmayan ilişkileri öğrenmesini sağlar. Bu katmanda, her nöronun çıkışı, belirli bir

aktivasyon fonksiyonundan geçirilerek hesaplanır. Bu sayede ağ daha karmaşık ve yüksek seviyeli özellikleri öğrenebilir. CNN’de aktivasyon fonksiyonu olarak çoğunlukla ReLU kullanılmaktadır [88].

Havuzlama Katmanı: Bu katmanın amacı, konvolüsyon katmanlarından çıkan verinin boyutunu azaltmaktır. Bu katmanda maksimum, minimum veya ortalama gibi çeşitli filtre matrisleri kullanılarak veri boyutları küçültülür. Havuzlama sırasında bazı veri kayıpları meydana gelir, bu da sonuç performansının düşmesine neden olabilir. Ancak, havuzlama işlemi ağı aşırı ezberlemesini engeller ve bir sonraki ağ katmanlarının hesaplama yükünü azaltır. Havuzlama işlemi, gereksiz bilgileri filtreleyerek modelin daha önemli özelliklere odaklanmasını sağlar [88].

Tam Bağlantılı Katman: Genellikle, her CNN mimarisinin sonunda bulunan bu katmandaki her nöron, önceki katmandaki tüm nöronlara bağlıdır. Tam bağlı katman, genellikle sınıflandırma görevlerinde kullanılır. Bu katman, giriş verilerini düzleştirir ve belirli sınıflara ayırmak için kullanılır. Örneğin, bir görüntü sınıflandırma görevinde, tam bağlı katman, görüntünün hangi sınıfa ait olduğunu belirler [78].

Seyreltme Katmanı: CNN’de büyük veriler ile eğitim işlemi yapıldığından aşırı öğrenme adı verilen ağı ezberlemesi gerçekleşebilir. Bu katmanda uygulanan temel mantık ağı ezberlemesinin önüne geçmek için ağda ezber yapan bazı düğümlerin ortadan kaldırılmasıdır [87].

Sınıflandırma Katmanı: Tam bağlı katmandan sonra gelen sınıflandırma katmanı, sınıflandırılacak öğe sayısı kadar sonuç üretir. Bu sonuçların her biri, belirli bir sınıfı temsil eder. Sınıflandırıcı katman için farklı türde sınıflandırıcılar kullanılabilir, ancak genellikle softmax sınıflandırıcı tercih edilir [87].

2.4.6 Derin öğrenme modelleri

Derin öğrenme modelleri, belirli bir mimariye dayanan ve belirli bir veri kümesi üzerinde eğitilmiş spesifik modellerdir. Her bir model belirli problemleri çözmek üzere optimize edilmiş ve eğitilmiştir [87].

2.4.6.1 LeNet

Başarılı ilk CNN olarak bilinen LeNet 1998 yılında Yann LeCun ve ark. tarafından geliştirilmiştir [89]. İki konvolüsyon, iki havuzlama ve iki tam bağlantılı katmandan oluşur. MNIST (el ile yazılmış rakamlar) veri seti kullanılmıştır. LeNet, CNN'in temelini atmış ve daha sonraki derin öğrenme modellerinin geliştirilmesine önemli katkılar sağlamıştır [89].

2.4.6.2 AlexNet

Derin öğrenmenin dünya çapında duyulması, 2012 yılında gerçekleştirilen ImageNet yarışmasının, derin öğrenme mimarisi ile tasarlanan AlexNet modeli tarafından kazanılması ile olmuştur [90]. AlexNet'in bu mimarisi, bilgisayarlı nesne tanımlamadaki hata oranını büyük ölçüde azaltarak %26,2'den %15,4'e düşürmüştür. AlexNet, 1000 farklı nesneyi sınıflandıracak şekilde tasarlanmıştır [87].

2.4.6.3 ZF Net

AlexNet'in ImageNet yarışmasındaki başarısından sonra, derin öğrenme yöntemleri daha sık kullanılmaya başlanmış ve her seferinde daha yüksek başarılar elde edilmiştir. Zeiler ve Fergus'un tasarlamış olduğu ZF Net, 2013 yılında %11,2'lik hata oranıyla ImageNet yarışmasının kazananı olmuştur [91]. Bu model AlexNet'in geliştirilmiş halidir [88, 91].

2.4.6.4 VGG Net

Oxford Üniversitesi'nden Simonyan ve Zisserman'ın geliştirdiği VGGNet mimarisi [92], ImageNet 2014 yarışmasında hata oranını %7.3'e düşürerek yüksek bir performans sergilemiştir. Bu mimari, VGG16 ve VGG19 gibi farklı konvolüsyon katman sayıları olan altı farklı model seçeneği sunmaktadır. VGGNet, AlexNet mimarisine dayanmakla birlikte, daha fazla konvolüsyon katmanı içermesi ve daha küçük filtre boyutları kullanması gibi önemli farklılıklar taşımaktadır. VGGNet'in başarısı, derin öğrenme mimarilerinin nesne tanımda çok etkili olabileceğini kanıtlamıştır [92].

2.4.6.5 GoogLeNet

GoogLeNet, 2014 yılında yapılan ImageNet yarışmasında %5,7'lik hata oranıyla birinci olmuştur. Bu mimari, karmaşık bir yapıya sahiptir ve Inception

modülü ile farklı boyutlarda filtreleme yaparak önceki derin öğrenme mimarilerinden ayrılır. Inception modülü, farklı boyutlardaki filtreleri tek bir katmanda birleştirerek daha az katmanla daha fazla bilgi işlemeyi mümkün kılar. Bu sayede, GoogLeNet daha hızlı ve verimli bir şekilde eğitilebilir [93].

2.4.6.6 ResNet

Kaiming He, Xiangyu Zhang ve ark. tarafından 2015 yılında tasarlanan bu model residual bloklardan oluşmaktadır [94]. 2015 yılında gerçekleştirilen ImageNet yarışmasının kazananı Microsoft ResNet olmuştur. İnsanlar görüntüleri ortalama %5-%10 hata oranı ile sınıflandırırken, ResNet yarışmada %3.6'lık bir hata oranı yakalayarak insandan daha iyi görsel tanıma yaptığını göstermiştir. Bu mimari, önceki mimarilere kıyasla daha fazla derinliğe sahiptir ve katman sayısı diğer derin öğrenme mimarilerinden daha fazladır [94].

2.4.6.7 Dense-Net

DenseNet, 2017 yılında Gao Huang ve ekibi tarafından tanıtılan bir derin öğrenme modelidir [95]. Bu model, her katmanın doğrudan önceki tüm katmanlara bağlı olduğu bir yapıya sahiptir. Her bir katman, önceki katmanlardan elde edilen öznetelik haritalarını girdi olarak kullanırken, kendi öznetelik haritalarını da sonraki tüm katmanlara iletmektedir. DenseNet'in sunduğu başlıca avantajlar arasında gradyan kaybı sorununu hafifletme, özneteliklerin daha etkili bir şekilde yayılmasını sağlama, öznetelik tekrar kullanımını teşvik etme ve parametre sayısını önemli ölçüde azaltma yer almaktadır [95].

2.4.6.8 U-Net

Ronneberger, Fischer ve Brox, biyomedikal görüntü segmentasyonu için geliştirdikleri U-Net'i 2015 yılında yayınladıkları 'U-Net: Biyomedikal Görüntü Segmentasyonu için Evrişimli Ağlar' makalesinde duyurdular [96]. "U" harfine benzer biçimdeki mimarisi nedeniyle bu ismi alan U-net, iki ana bölümden oluşmaktadır ve ilk bölüm daralma bölümüdür. Klasik CNN mimarisinden oluşan bu bölüm ReLU aktivasyon fonksiyonu ve havuzlama katmanlarından oluşur. U-net modelinin en önemli kısmı olan genişleme bölümü ise, daralma bölümünden gelen özellik haritalarını alarak, girişle aynı boyutta ve çözünürlükte görüntü üretmek için genişletmektedir [96, 97].

U-net yapısının sahip olduğu bazı üstünlükler vardır. CNN modelleri genellikle büyük veri kümelerine ihtiyaç duyar ancak tıbbi görüntüleme gibi alanlarda bu verileri toplamak zordur. U-Net, basit ve esnek bir yapıya sahiptir ve az sayıda eğitim görüntüsüyle bile yüksek kalitede segmentasyon sonuçları verir [98].

2.4.6.9 R-CNN

Görüntü sınıflandırma, genellikle bir görüntüdeki nesnenin ne olduğunu tahmin etme işlemiyken; nesne tanımlama, nesnenin konumu ve sınırlarının belirlenmesidir. R-CNN modeli nesne tanımlama için tasarlanmıştır. Bu model; görüntülerin alınması, seçici arama ile 2000 farklı bölge önerisinin yapılması, her bir önerinin CNN mimarisine verilmesi ve CNN çıktısının düzenlenmesi olmak üzere dört ana bölümden oluşur. Ancak, R-CNN'in görüntüdeki her bölge önerisi için CNN'den 2000 ileri geçiş gerektirmesi ve üç farklı modelin ayrı ayrı eğitilmesi gibi dezavantajları bulunmaktadır. Bu işlemler, test aşamasında zaman kaybına ve eğitimin zorluğuna neden olur. Bu sorunları aşmak için Fast R-CNN modeli geliştirilmiş olup bu model, her görüntü için sadece bir kez CNN çalıştırarak 2000 öneri arasında hesaplamaları paylaşır, böylece eğitim ve test sürelerini kısaltır. Yine de karmaşık olan eğitim hattını iyileştirmek amacıyla tasarlanan Faster R-CNN ise son konvolüsyon katmanından sonra bir Bölge Öneri Ağı eklenmesiyle daha verimli hale getirilmiştir. Bu üç model, PASCAL VOC veri seti üzerinde test edilmiştir ve sonuçlar Tablo 2.2'de sunulmuştur [87].

Tablo 2.2 R-CNN, Fast R-CNN ve Faster R-CNN modellerinin karşılaştırılması [87]

	R-CNN	Fast R-CNN	Faster R-CNN
Görüntü başına test süreleri	50sn	2sn	0.2sn
Hızlanma	1x	25x	250x
Ortalama tahmin(%)	66	66.9	66.9

2.4.6.10 YOLO

Bilgisayarla görme alanında nesne tespiti, You Only Look Once (YOLO) mimarisinin Redmon ve ark. tarafından 2016'da tanıtılmasıyla büyük bir evrim geçirmiştir [99]. YOLO, geleneksel iki aşamalı nesne tespiti yöntemlerinden farklı olarak, tek bir işlemle sınır kutuları ve sınıf olasılıklarını aynı anda tahmin edebilen bir mimari sunmaktadır. Bu yenilik, gerçek zamanlı uygulamalar için önemli bir

avantaj sağlayarak nesne tespiti alanında bir dönüm noktası olmuştur. YOLO'nun önemi sadece tek aşamalı yaklaşımında değil, aynı zamanda ilk versiyonu olan YOLOv1'den günümüzdeki YOLOv8'e kadar süregelen sürekli gelişiminde yatmaktadır. Her yeni sürüm, mimaride yenilikçi gelişmeler sunarak YOLO'yu daha yetenekli ve esnek hale getirmektedir. Örneğin, YOLOv2 ve YOLOv3, performans ve doğruluk açısından önemli iyileştirmeler getirirken, YOLOv4 ve YOLOv5, hesaplama verimliliği ve hız konusunda gelişmeler sunmuştur. En son sürüm olan YOLOv8 ise daha karmaşık görevleri yüksek doğrulukla gerçekleştirebilmektedir [100].

YOLO'nun temel amacı, doğruluk ve hız arasında optimum bir denge kurarak araştırmacılar için etkili ve kullanışlı bir çözüm sunmaktır. Bu, YOLO'nun geniş bir uygulama yelpazesinde kullanılabilirliğini artırmış ve onu bilgisayarla görme alanında bir standart haline getirmiştir. YOLO'nun her iterasyonu, daha yüksek performans ve daha geniş kapsamlı uygulama alanları sunarak, nesne tespiti teknolojisinin sınırlarını sürekli olarak genişletmektedir [100].

YOLOv5: YOLOv5, *Graphics Processing Unit* (GPU) hızlandırmasıyla optimize edilmiştir ve yüksek hızlı nesne tespiti yapma yeteneğine sahiptir. YOLOv5 mimarisi *backbone*, *neck* ve *head* olmak üzere 3 temel bileşenden oluşmaktadır. Bu bileşenler bir araya gelerek nesne tespiti işlemini gerçekleştirir. *Backbone* bileşeni, temel görüntü özelliklerini çıkarmak için kullanılan bir CNN modelidir. *Neck* bileşeni, *backbone*'dan alınan çıktıları işlemek ve daha yüksek seviyeli özellikler elde etmek için kullanılır. Bu aşamada ölçeklendirme, birleştirme ve öznetelik düzenleme işlemleri gerçekleştirir. Son olarak, *Head* bileşeni nesne tespitinin yapıldığı aşamadır; bu bileşen önceden belirlenmiş sınıf sayısına göre sınıflandırma ve sınırlayıcı kutu tahmini yapar [101].

YOLOv8: YOLO serisinin mevcut en son versiyonu YOLOv8'dir ve diğer YOLO modellerinden daha hızlı bir performans sergilemektedir [102]. YOLOv5'ten farklı olarak Sabitleyici Olmayan Algılama (*Anchor-Free Detection*) ve Mozaik Büyütme (*Mosaic Augmentation*) güncellemeleri gerçekleştirilmiştir [101].

Bu modelin yapısı üç ana bölümden oluşur: *backbone*, *neck* ve *head*. *Backbone* kısmında CSPDarknet53 adı verilen bir yapı kullanılır. Bu bölüm, modelin giriş olarak aldığı görüntülerdeki önemli özellikleri çıkartır ve bir özellik haritası oluşturur. *Neck* kısmında *Path Aggregation Network* (PANet) kullanılır. Bu yapı, *backbone* tarafından

çıkarılan özellikleri *head* bölümüne aktarır ve bilgiyi hem aşağıdan yukarıya hem de yukarıdan aşağıya yönlendirir. Bu yöntem, düşük seviyeli özelliklerin etkili bir şekilde yayılmasını ve nesne konumlarının daha doğru belirlenmesini sağlar. YOLOv8'in *head* kısmı, YOLOv5'e benzerlik gösterir. *Head*, tespit edilen nesnelerin sınıflandırılması ve konumlarının belirlenmesi için kullanılır [103].

2.4.7 Derin öğrenme kütüphaneleri

Derin öğrenmenin yapısında çeşitli programlama dillerinde birçok kütüphane bulunur ve bu kütüphaneler, uygulamalarda kullanıcıların işini büyük ölçüde kolaylaştırır. Her bir kütüphane, belirli işlemlere ve özelliklere sahip olup, farklı ihtiyaçlara yönelik çözümler sunar. Bu çeşitlilik, araştırmacılardan geliştiricilere kadar geniş bir yelpazede kullanıcıların, derin öğrenme projelerini daha verimli ve etkili bir şekilde gerçekleştirmelerine olanak tanır [104].

- TensorFlow: Google tarafından geliştirilmiş açık kaynak kodlu bir derin öğrenme kütüphanesidir. Bu kütüphane, çeşitli programlama dilleriyle ve farklı donanım platformlarıyla uyumlu çalışabilme yeteneğine sahiptir. TensorFlow, özellikle görüntü işleme ve sayısal hesaplamalar alanında sıkça tercih edilmektedir [88].

- Caffe: Berkeley Üniversitesi tarafından geliştirilen hızlı ve verimli bir derin öğrenme kütüphanesidir. Python ve Matlab arayüzleri ile C++ programlama dili kullanılarak tasarlanmıştır. Caffe, önceden eğitilmiş modeller sunarak, kullanıcıların yeni modeller oluşturmak için zaman ve çaba harcamadan derin öğrenme uygulamalarını hızlı bir şekilde hayata geçirmelerine olanak tanır [104].

- Theano: Derin öğrenme modelleri geliştirmeyi kolaylaştıran bir matematiksel ifade kütüphanesidir. Bu Python kütüphanesi, çok boyutlu dizileri içeren matematiksel ifadeleri verimli bir şekilde tanımlama, optimize etme ve değerlendirme imkânı sunar [87].

- Torch: Karmaşık sorunları basitleştirerek, çözüm algoritmalarını hızlı ve esnek şekilde geliştiren bir kütüphanedir. Bu kütüphane, görüntü işleme, ses işleme, video ve resim gibi çeşitli formatlarla çalışma imkânı sunar. Torch, Lua ve Python gibi programlama dilleriyle desteklenmektedir [104].

- Keras: Python ile geliştirilmiş bir derin öğrenme kütüphanesidir. Derin öğrenme modellerinin hızlı ve kolay bir şekilde oluşturulmasını, eğitilmesini ve test edilmesini sağlar. Keras, TensorFlow ve Theano gibi alt kütüphanelerin üzerine inşa edilmiştir [87, 105].

- MXnet: C, Python, MATLAB, JavaScript, R, Julia ve Scala gibi çeşitli programlama dilleriyle desteklenen bu kütüphane, çoklu dil desteği sunan bir araç olarak öne çıkmaktadır. Bu özellik, kullanıcıların gerçekleştirdikleri çalışmaları farklı programlama dillerinde kolayca karşılaştırma imkânı sağlar [105].

- PyTorch; Derin öğrenme modelleri oluşturmayı kolaylaştıran Python tabanlı bir kütüphanedir. Diğer derin öğrenme kütüphanelerinin aksine, karmaşık mimariler oluşturmada daha fazla esneklik sağlayan dinamik hesaplama kullanır. PyTorch, birçok kütüphaneyle birlikte çalışır. PyTorch bellek kullanımı açısından son derece verimlidir; bu sayede daha büyük derin öğrenme modellerinin eğitimini mümkün kılar [88].

2.4.8 Diş hekimliğinde yapay zekâ kullanım alanları

Yapay zekanın sağlık alanındaki uygulamaları büyük bir potansiyele sahiptir. İlaç keşfi, uzaktan hasta izleme, tıbbi teşhis ve görüntüleme, risk yönetimi, giyilebilir cihazlar, sanal asistanlar ve hastane yönetimi gibi birçok önemli alanda kullanımı öne çıkmaktadır [106-109]. Diş hekimliğinde ise özellikle normal ve anormal yapıların tanımlanması, hastalıkların teşhisi ve tedavi sonuçlarının öngörülmesi gibi konularda araştırmalar devam etmektedir [110-112].

Yapay zekâ Ağız, Diş ve Çene Radyolojisi alanında; 2D veya 3D radyografilerin otomatik olarak yorumlanması, görüntü analizi, diş tespiti ve segmentasyonu, kemik kalitesinin değerlendirilmesi, diş çürüğü ve periapikal patoloji tespiti, dişlerin kök morfolojilerinin belirlenmesi, anatomik landmarkların tanımlanması amaçlarıyla kullanılmaktadır [113-117]. Ayrıca, lenf nodu metastazlarının tespiti, osteoporoz riskinin değerlendirilmesi, Sjögren sendromu ve ağız kanseri taramaları gibi uygulamalarda da yapay zekâ algoritmalarından yararlanılmaktadır [118-121].

Ağız, Diş ve Çene Cerrahisi alanında yapay zeka; robotik cerrahide, mandibular üçüncü molar dişlerin çekimi sırasında yaşanabilecek güçlükler ve olası

komplasyonların tahmininde, implant planlama, peri-implantitis tespiti ve implantların model tespitinin gerekleřtirilmesinde kullanılmaktadır [118, 122].

Yapay zekâ kullanılarak yapılan periodontoloji alıřmalarında, doęal diřlerin etrafındaki kemik kaybı miktarı, implant evresindeki kemik yoęunluęu ve periodontal hastalık geliřim riski deęerlendirilmektedir [123-125].

Protetik diř tedavisinde yapay zekâ; *Computer-Aided Design/Computer-Aided Manufacturing* (CAD/CAM) uygulamaları, dijital glř tasarımı, hareketli ve sabit protezlerin planlaması, renk seimi gibi birok alanda etkin bir řekilde kullanılmaktadır [118, 126].

Yapay zekâ, ortodonti alanında maloklzyonların sınıflandırılması, tedavi planlaması, sefalometrik analizde anatomik landmarkların belirlenmesi, byme geliřmenin deęerlendirilmesi, tedavi sonularının deęerlendirilmesi ve fotoęraflar zerinden sınıflandırma yapılması gibi birok alanda kullanılmaktadır [118, 127-129]. Maloklzyonu olan hastalarda, ortodontik tedavi ncesinde, tedavinin prognozu zerinde byk etkisi olan diř ekimine ihtiya olup olmadıęını belirlemek iin yapay zekâ kullanılmaktadır [130]. Yapay zekâ ile ortognatik cerrahi gereklilięinin deęerlendirilmesi de alıřma alanı bulmuřtur. Choi ve ark.'nın yaptıkları alıřmada, yapay zekâ ortognatik cerrahi gereksinimini belirlemede % 96 oranında bařarılı olmuřtur [131].

Endodonti alanındaki alıřmalar; kk kanalı uzunluęunu, vertikal kk kırıklarını, kk morfolojisini, pulpa hastalıklarını, periapikal lezyonları, kanal tedavisi bařarısızlıklarını, postoperatif aęrıyı ve vaka zorluęunu tahmin etmeye odaklanmıřtır [117, 118, 132-134].

Restoratif diř tedavisinde yapay zekâ; periapikal, bitewing ve panoramik rntgenler zerinden rk tespitinde kullanılmaktadır. Ayrıca intraoral fotoęraflar ile rk tespiti yapan alıřmalar da bulunmaktadır [135-137].

Pedodonti alanında ise diř rę tespiti, kronolojik yař tespiti, ocukların aęız saęlıęı durumunun ve tedavi ihtiyalarının tahmini, st diřlerinde plak tespiti, fissr rtclerin tespiti ve sınıflandırılması, diřlerin otomatik tespiti gibi alıřmalar bulunmaktadır [138-141].

3. GEREÇ VE YÖNTEMLER

Bu çalışma için Bezmialem Vakıf Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu'na başvurulmuş ve çalışma E-54022451-050.05.04-122625 numaralı belge ve 2023/264 karar numarası ile onaylanarak; Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Kliniği'nde gerçekleştirilmiştir.

Bu tez çalışmasında; CNN'lere dayalı bir yapay zekâ modeli olan Craniocatch (Eskişehir, Türkiye) uygulamasında, T2 ağırlıklı sagittal MR görüntüleri kullanılarak TME'yi oluşturan anatomik yapılardan glenoid fossa, artiküler eminens, mandibular kondil ve artiküler disk tanıtılmıştır. Artiküler diskin konumu CNN'e dayalı yapay zekâ modeli kullanılarak normal veya anterior pozisyonda olarak kategorize edilmiştir.

3.1 Görüntülerin Seçilmesi

Bu retrospektif çalışmada, Ocak 2018-Temmuz 2023 yılları arasında Bezmialem Vakıf Üniversitesi Diş Hekimliği Fakültesi Ağız Diş ve Çene Radyolojisi Anabilim Dalı'na; diş gıcırdatma, bruksizm, ağız açıklığında kısıtlılık, TME bölgesinde ağrı şikayetleri ile başvuran hastalara ait TME MR görüntüleri kullanılmıştır.

Dahil edilme kriterleri;

- 18 ile 65 yaş arasındaki kişilere ait MR görüntüleri
- Diagnostik açıdan yeterli radyografik görüntü kalitesi olan MR görüntüleri
- TME bölgesine ait geçirilmiş cerrahi operasyonu olmayan kişilere ait MR görüntüleri
- TME'de şiddetli dejeneratif değişiklik gözlenmeyen kişilere ait MR görüntüleri
- Bifid kondil veya benzeri anatomik varyasyona sahip olmayan kişilere ait MR görüntüleri
- TME bölgesine ait travma öyküsü olmayan kişilere ait MR görüntüleri
- TME'de benign ya da malign tümör mevcudiyeti olmayan kişilere ait MR görüntüleri

- Diskte anterior haricinde medial ya da laterale disk deplasmanı olmayan kişilere ait MR görüntüleri
- Görüntüde teşhise engel olacak boyutta ciddi MRG artefaktları olmayan kişilere ait MR görüntüleri

Dahil edilmeme kriterleri;

- TME bölgesine ait geçirilmiş cerrahi operasyon
- TME’de şiddetli dejeneratif değişiklik
- Bifid kondil veya benzeri anatomik varyasyon
- TME bölgesine ait travma öyküsü
- TME’de benign ya da malign tümör mevcudiyeti
- Diskte anterior haricinde medial ya da laterale disk deplasmanı
- Görüntüde teşhise engel olacak boyutta ciddi MRG artefaktları

3.2 Radyografik Veri Setlerinin Elde Edilmesi

Tez çalışmamızın veri seti, Bezmialem Vakıf Üniversitesi Tıp Radyolojisi Anabilim Dalı’nda bulunan 1.5T MR cihazı (Siemens Avanto, Erlangen, ALMANYA) ile çekilen MR görüntülerinin retrospektif olarak taranması ile oluşturulmuştur. Veri setine dahil edilen MR görüntüleri, SYNAPSE PACS (FUJIFİLM, Tokyo, JAPONYA) programı ile kimlik bilgilerini içermeyecek şekilde anonimize edilmiş ve DICOM formatından JPEG formatına dönüştürülerek kaydedilmiştir.


3.3 Görüntü Değerlendirmesi

Hazırlanan veri setleri CranioCatch yazılımına (Eskişehir, Türkiye) aktararak projeler oluşturulmuş ve etiketlemeye hazır hale getirilmiştir. Etiketleme, bir görüntüdeki belirli alanların tanıtılması ve bu alanlarda bulunan nesnelerin hangi bölgeye ait olduğunun belirlenmesi işlemidir. Hastalardan elde edilen toplamda 901 sagittal MR görüntüsü kırılmadan 640 x 640 piksel boyutuna yeniden boyutlandırılmıştır. Görüntü sayısının artırılması amacıyla mevcut görüntülere veri artırma (augmentasyon) uygulanmıştır. Bunlar sağa, sola, aşağı, yukarı çevirme; doyumluk düzeltme, parlaklık düzeltme, renk tonu ekleme ve mozaik veri artırmadır. Veri artırma, mevcut eğitim veri kümesini çeşitli yöntemlerle genişletmeyi ve çeşitlendirmeyi hedefleyerek modelin daha iyi performans göstermesine yardımcı olur [142].


T2 ağırlıklı sagittal MR görüntülerinde, TME'yi oluşturan yapılardan glenoid fossa, artiküler eminens, mandibular kondil ve artiküler disk (normal konumda ve anterior konumda) 3 yıllık deneyime sahip bir araştırma görevlisi ve 7 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanı tarafından CranioCatch (Eskişehir, Türkiye) yazılımı kullanılarak etiketlenmiştir. Etiketlenen görüntüler 7 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanı ve 8 yıllık Radyoloji uzmanı tarafından kontrol edilerek anlaşma sağlanamayan kesitler veri setinden çıkarılmıştır.

Manyetik rezonans görüntüleri üzerinde etiketleme; TME bölgesindeki yapıların serbest çizim tekniğiyle belirlenerek çizilmesi (segmentasyon tekniği, poligon yöntemi) şeklinde gerçekleştirilmiştir (Şekil 3.1, 3.2, 3.3, 3.4, 3.5).







Şekil 3.1: Mandibular kondilin poligon yöntemi ile etiketlenmesi.



Şekil 3.2: Glenoid fossanın poligon yöntemi ile etiketlenmesi.



Şekil 3.3: Artiküler eminensin poligon yöntemi ile etiketlenmesi.



Şekil 3.4: Normal pozisyondaki artiküler diskin poligon yöntemi ile etiketlenmesi.



Şekil 3.5: Anteriora deplase artiküler diskin poligon yöntemi ile etiketlenmesi.

3.4 Derin Öğrenme Mimarisi

Çalışmamızda derin öğrenme, PyTorch, Opencv, Numpy, Pandas, TorchVision, Torch, Tensorboard, Seaborn kütüphaneleri ve Python açık kaynak programlama dili (v.3.6.1; Python Software Foundation, Wilmington, DE, ABD) kullanılarak gerçekleştirilmiştir. TME bölgesinin segmentasyonu için hem YOLOv5 hem de YOLOv8 mimarisi kullanılarak iki ayrı mimarinin başarı sonuçları karşılaştırılmıştır.

3.5 Model Geliştirilmesi

Python açık kaynak programlama dili (v.3.6.1; Python Software Foundation, Wilmington, DE, ABD) ve PyTorch kütüphanesi model geliştirme için kullanılmıştır. Modellerin eğitimi, 16 GB RAM ve NVIDIA Tesla V100 ekran kartı ile donatılmış bir bilgisayar kullanılarak gerçekleştirilmiştir.

3.6. Eğitim Aşaması

Yapay zekâ sistemlerinin geliştirilmesi ve başarılı olması, veri kümesinin büyüklüğünden doğrudan etkilenmektedir. Çalışmamızın segmentasyon kısmında en uygun CNN algoritmasının ağırlık faktörlerini tahmin etmek ve üretmek için mevcut veri seti; eğitim, doğrulama ve test seti şeklinde 3 gruba ayrılmıştır. Eğitim ve doğrulama veri setleri bu CNN algoritmaları için optimal ağırlık faktörlerini tahmin etmek ve oluşturmak için kullanılmıştır.

Eğitim veri seti: Modelin eğitilmesi için kullanılan veri setidir [143].

Doğrulama veri seti: Geliştirme seti olarak da bilinen bu veri seti, modelin hiperparametrelerini ayarlamak ve genel performansını değerlendirmek için kullanılır. Eğitim sürecinden bağımsız olan ve modelin eğitim sırasında görmediği örnekleri içerir. Bu set, modelin aşırı uyum sağlamasını önlemek açısından önemlidir [143].

Test veri seti: Modelin son performansını tarafsız olarak değerlendirmek için kullanılan ayrı bir veri setidir. Bu veri seti, modelin daha önce hiç görmediği örneklerden oluşur ve modelin performansını objektif bir şekilde ölçer [143].

TME'yi oluşturan anatomik yapılardan mandibular kondil, glenoid fossa, artiküler eminens ve artiküler diskin (normal ve anteriora deplase pozisyonda) tanıtılması için çalışılan veri seti 901 adet T2 ağırlıklı sagittal MR görüntüden oluşmaktadır. Bu veri seti üzerinden 3582 adet etiketleme yapılmıştır. Veri setinin yaklaşık olarak %10'u test, %10'u doğrulama, %80'i de eğitim veri seti olarak ayrılmıştır (Tablo 3.1). Modelin eğitimi 500 epoch (eğitim tur sayısı) yapılarak gerçekleştirilmiştir. YOLOv5 ve YOLOv8 modellerinin öğrenme hızı (learning rate) 0.01 değerindedir.

Tablo 3.1: Çalışmada kullanılan veri seti sayıları

Etiketlenen Bölge	Eğitim Veri Seti Sayısı	Doğrulama Veri Seti Sayısı	Test Veri Seti Sayısı
Kondil	721	90	90
Glenoid fossa	707	88	88
Artiküler eminens	721	90	90
Artiküler disk (normal konumda)	507	63	63
Anteriora deplase artiküler disk	215	26	26

3.7 İstatiksel Analiz

Karmaşıklık matrisi, bir sınıflandırma sistemi tarafından yapılan gerçek ve tahmin edilen sınıflandırmaları özetleyen matris formatında bir tablodur. Sistemlerin performansı matristeki veriler kullanılarak değerlendirilir [144]. Bu çalışmada da model performansını değerlendirmek için karmaşıklık matrisi kullanılmıştır. Aynı zamanda karmaşıklık matrisi ile birlikte, Kesinlik–Duyarlılık eğrisi (*Precision–Recall Curve/PR*) oluşturulmuştur.

3.7.1. Karmaşıklık matrisi hesaplama prosedürü

Karmaşıklık matrisi ikili sınıflandırma görevlerinde gerçek değerler ile sınıflandırıcının tahmin ettiği değerleri gösteren, 2x2 boyutunda matris şeklinde bir tablodur. Karmaşıklık matrisinde sistemlerin performansı matristeki veriler kullanılarak değerlendirilir. Tahmin edilen değerlerin gerçek değerlerle karşılaştırması yapılabilmektedir [145].

Tablo 3.2: İkili sınıflandırma için karmaşıklık matrisi

		GERÇEK	
		POZİTİF	NEGATİF
TAHMİN	POZİTİF	DP	YP
	NEGATİF	YN	DN

Modelin başarısını değerlendirmek için kullanılan metrikler şu şekildedir:

Doğru pozitif (DP): TME anatomik yapıları doğru tespit edilmiştir.

Yanlış pozitif (YP): TME anatomik yapıları yanlış tespit edilmiştir.

Yanlış negatif (YN): TME anatomik yapıları tespit edilememiştir.

Çalışmamızda doğru negatif (DN) metriği kullanılmamıştır. Nesne tespit algoritmalarında doğru negatif (DN) değerinin kullanılması mümkün değildir çünkü herhangi bir görüntü içinde algılanmaması gereken çok yüksek sayıda sınırlayıcı kutu mevcuttur [146].

3.8 Performans Değerlendirme

Doğruluk (accuracy): Doğru tahmin edilen örneklerin toplam örnek sayısına oranıdır. Modelin değerlendirilmesinde kullanılır ancak tek başına yeterli bir parametre değildir [147].

$$\text{Doğruluk oranı} = \frac{DP+DN}{DP + DN + YP + YN}$$

Duyarlılık (recall, sensitivite): Gerçek pozitif örneklerin ne kadarının pozitif olarak sınıflandırıldığını gösterir. Doğru pozitif örneklerin gerçek pozitiflere oranı olarak ifade edilebilir. Yanlış negatifliklerin çok olduğu durumlarda duyarlılık değeri düşük çıkmaktadır dolayısıyla model seçiminde yüksek duyarlılık değerine sahip parametreler seçilmelidir [147].

$$\text{Duyarlılık} = \frac{DP}{DP + YN}$$

Kesinlik değeri (precision): Pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. Yalancı pozitifliklerin az olması modelin performansı açısından önemli olduğundan, kesinlik değerinin yüksek olması istenir [147].

$$\text{Kesinlik} = \text{DP} / (\text{DP} + \text{YP})$$

F1 skoru: Kesinlik ve duyarlılık skorlarının ağırlıklı (harmonik) ortalamasıdır [147]. Formülü ise şu şekildedir;


$$\text{F1 skoru} = 2 \times (\text{Duyarlılık} \times \text{Kesinlik}) / (\text{Duyarlılık} + \text{Kesinlik})$$

Birleşim üzerinden ortalama kesişme (IoU): Bir görüntüdeki tahmin edilen kutuların ve gerçek kutuların kesişim (örtüşme) alanının birleşim alanına oranıdır. IOU eşiği 0.50 olarak ayarlanırsa yalnızca IOU değeri ≥ 0.50 olan tahminler gösterilecektir. Uluslararası alanda tanınmış bir nesne sınıflandırma, algılama ve segmentasyon yarışması olan PASCAL Görsel Nesne Sınıflandırma, Algılama ve Segmentasyon Yarışması'nda IOU eşiği olarak 0.50 değeri kabul edilmiştir [148]. Tez çalışmamızda da IOU eşiği 0.50 olarak ayarlanmıştır.

Ortalama kesinlik değerlerinin ortalaması (Mean Average Precision, mAP): Her sınıf için hesaplanan ortalama kesinlik (*average precision*, AP) değerlerinin ortalamasını ifade eder. Nesne algılama modellerinde doğruluğun değerlendirilmesi için kullanılır. Değerler 0 ile 1 arasında değişir ve sonuçların 1'e yakın olması, modelin performansının yüksek olduğunu gösterir [149].

3.9 Kesinlik- Duyarlılık Eğrisi (PR Eğrisi, Precision-Recall Curve)

Kesinlik – Duyarlılık (PR) eğrisi, kesinlik ve duyarlılık kullanılarak makine öğrenimi model performansını ölçen bir grafikdir. Bu eğri, y-ekseni üzerinde kesinlik ve x-ekseni üzerinde duyarlılık değerlerinin birçok eşik değeri boyunca hesaplanmasıyla oluşturulur. Eğri, sınıflandırma eşiği değiştiğinde kesinlik ve duyarlılık değerlerinin nasıl değiştiğini gösteren bir dengeyi ortaya koyar. PR eğrilerinde, eğrinin sağ üst köşeye yaklaşması başarı oranını artırır ve eğri altında kalan alan ne kadar büyükse, model o kadar iyi performans gösterir [150].




Şekil 3.6: Kesinlik-duyarlılık (PR) eğrisi.

4. BULGULAR


Çalışmamızda, 901 adet T2 ağırlıklı sagittal MR görüntüsü üzerinde, TME'yi oluşturan anatomik yapılardan mandibular kondil, glenoid fossa, artiküler eminens, normal konumdaki artiküler disk ve anterior konumdaki artiküler diskin segmentasyonu YOLOv5 ve YOLOv8 modelleri kullanılarak yapılmış ve modellerin başarısı araştırılmıştır. Model performansları karmaşıklık matrisi kullanılarak değerlendirilmiştir.

Mandibular kondil segmentasyonunda, YOLOv5 modeli 90 DP, 1 YP ve 0 YN sonuç üretmiştir. Değerlere ait karmaşıklık matrisi Şekil 4.1'de gösterilmiştir.




Şekil 4.1: Mandibular kondil segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.

Mandibular kondil segmentasyonunda, YOLOv8 modeli 89 DP, 2 YP ve 1 YN sonuç göstermiştir. Değerlere ait karmaşıklık matrisi 4.2'de gösterilmiştir.




Şekil 4.2: Mandibular kondil segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.

Artiküler eminens segmentasyonunda, YOLOv5 modeli 89 DP, 3 YP ve 1 YN sonuç üretmiştir. Değerlere ait karmaşıklık matrisi 4.3'te gösterilmiştir.




Şekil 4.3: Artiküler eminens segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.

YOLOv8 modeli ise 89 DP, 1 YP ve 1 YN sonuç göstermiştir. Bu değerlere ait karmaşıklık matrisi Şekil 4.4'te sunulmuştur.




Şekil 4.4: Artiküler eminens segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.

Glenoid fossa segmentasyonunda, YOLOv5 modeli 73 DP, 8 YP ve 15 YN sonuç göstermiştir. Bu değerlere ait karmaşıklık matrisi Şekil 4.5'te sunulmuştur.




Şekil 4.5: Glenoid fossa segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.

YOLOv8 modeli ise 85 DP, 1 YP ve 3 YN sonuç üretmiştir. Değerlere ait karmaşıklık matrisi Şekil 4.6’da gösterilmiştir.




Şekil 4.6: Glenoid fossa segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.

Normal konumdaki artiküler disk segmentasyonunda, YOLOv5 modeli 63 DP, 0 YP ve 0 YN sonuç göstermiştir. Değerlere ait karmaşıklık matrisi Şekil 4.7’de gösterilmiştir.




Şekil 4.7: Normal konumdaki artiküler disk segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.

YOLOv8 modeli ise 62 DP, 0 YP ve 1 YN sonuç üretmiştir. Değerlere ait karmaşıklık matrisi Şekil 4.8’de gösterilmiştir.




Şekil 4.8: Normal konumdaki artiküler disk segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.

Anterior konumdaki artiküler disk segmentasyonunda, YOLOv5 modeli 26 DP, 1 YP ve 0 YN sonuç üretmiştir. Değerlere ait karmaşıklık matrisi Şekil 4.9’da gösterilmiştir.



Şekil 4.9: Anteriora deplase artiküler disk segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.

YOLOv8 modeli ise 25 DP, 4 YP ve 1 YN sonuç göstermiştir. Değerlere ait karmaşıklık matrisi Şekil 4.10'da yer almaktadır.



Şekil 4.10 Anteriora deplase artiküler disk segmentasyonu için YOLOv8 modelinin normalize edilmiş karmaşıklık matris grafiği.

YOLOv5 ve YOLOv8 modellerinin mandibular kondil, glenoid fossa, artiküler eminens, normal konumdaki artiküler disk ile anterior konumdaki artiküler diskin segmentasyonları için DP, YP ve YN değerleri Tablo 4.1 ve 4.2’de gösterilmiştir.

Tablo 4.1: YOLOv5 ve YOLOv8 modellerinin mandibular kondil, glenoid fossa, artiküler eminens segmentasyonları için DP, YP ve YN değerleri

	Mandibular Kondil		Artiküler Eminens		Glenoid Fossa	
	YOLOv5	YOLOv8	YOLOv5	YOLOv8	YOLOv5	YOLOv8
DP	90	89	89	89	73	85
YP	1	2	3	1	8	1
YN	0	1	1	1	15	3

Tablo 4.2: YOLOv5 ve YOLOv8 modellerinin normal konumdaki artiküler disk ve anterior konumdaki artiküler disk segmentasyonları için DP, YP ve YN değerleri

	Artiküler Disk (Normal Konumda)		Artiküler Disk (Anterior Konumda)	
	YOLOv5	YOLOv8	YOLOv5	YOLOv8
DP	63	62	26	25
YP	0	0	1	4
YN	0	1	0	1

YOLOv5 ve YOLOv8 modellerinin mandibular kondil, glenoid fossa, artiküler eminens, normal konumdaki artiküler disk ile anterior konumdaki artiküler diskin segmentasyonları için DP, YP ve YN değerleri IoU eşik değerinin %50 olarak belirlenmesi ile elde edilmiştir. Bu değerlerden hesaplanan duyarlılık, kesinlik ve F1 skorları Tablo 4.3 ve 4.4’te gösterilmiştir.

Tablo 4.3: YOLOv5 ve YOLOv8 modellerinin mandibular kondil, glenoid fossa, artiküler eminens segmentasyonları için duyarlılık, kesinlik ve F1 skoru performans ölçüm değerleri


	Mandibular Kondil		Artiküler Eminens		Glenoid Fossa	
	YOLOv5	YOLOv8	YOLOv5	YOLOv8	YOLOv5	YOLOv8
Duyarlılık	1	0,9888888889	0,9888888889	0,9888888889	0,8295454545	0,9659090909
Kesinlik	0,989010989	0,978021978	0,9673913043	0,9888888889	0,9012345679	0,988372093
F1 skoru	0,9944751381	0,9834254144	0,978021978	0,9888888889	0,8639053254	0,9770114943

Tablo 4.4: YOLOv5 ve YOLOv8 modellerinin normal konumdaki artiküler disk ve anterior konumdaki artiküler disk segmentasyonları için duyarlılık, kesinlik ve F1 skoru performans ölçüm değerleri.


	Artiküler Disk (Normal Konumda)		Artiküler Disk (Anterior Konumda)	
	YOLOv5	YOLOv8	YOLOv5	YOLOv8
Duyarlılık	1	0,9841269841	1	0,9615384615
Kesinlik	1	1	0,962962963	0,8620689655
F1 Skoru	1	0,992	0,9811320755	0,9090909091

4.1 PR Eğrisi


Kesinlik-Duyarlılık (Precision-Recall, PR) eğrisi, modelin pozitif sınıf performansını değerlendirmeye odaklanır ve PR eğrisinde amaç, sağ üst köşedeki (1,1) noktasına mümkün olduğunca yakın olmaktır. Bu nokta, modelin tüm gerçek pozitif örnekleri doğru bir şekilde tespit ettiğini ve aynı zamanda hiçbir yanlış pozitif tespitle bulunmadığını gösterir. Bu durum, modelin ideal performansını temsil eder[150]. Çalışmamızda kullandığımız YOLOv5 ve YOLOv8 modellerinin mandibular kondil, glenoid fossa, artiküler eminens, normal konumdaki artiküler disk ile anterior konumdaki artiküler diskin segmentasyonları için oluşturulan PR eğrileri Şekil 4.11-4.20’de verilmiştir.




Şekil 4.11: YOLOv5 modelinin mandibular kondil segmentasyonu için PR eğrisi.




Şekil 4.12: YOLOv8 modelinin mandibular kondil segmentasyonu için PR eğrisi.




Şekil 4.13: YOLOv5 modelinin artiküler eminens segmentasyonu için PR eğrisi.




Şekil 4.14: YOLOv8 modelinin artiküler eminens segmentasyonu için PR eğrisi.




Şekil 4.15: YOLOv5 modelinin artiküler fossa segmentasyonu için PR eğrisi.




Şekil 4.16: YOLOv8 modelinin artiküler fossa segmentasyonu için PR eğrisi.




Şekil 4.17: YOLOv5 modelinin normal konumdaki artiküler disk segmentasyonu için PR eğrisi.



Şekil 4.18: YOLOv8 modelinin normal konumdaki artiküler disk segmentasyonu için PR eğrisi.



Şekil 4.19: YOLOv5 modelinin anteriora deplase artiküler disk segmentasyonu için PR eğrisi.



Şekil 4.20: YOLOv8 modelinin anteriora deplase artiküler disk segmentasyonu için PR eğrisi.

4.2 mAP Değerleri


Her sınıf için hesaplanan ortalama kesinlik-*average precision* (AP) değerlerinin ortalamasını ifade eder. Nesne algılama modellerinde doğruluğun değerlendirilmesi için kullanılır. Mandibular kondil, glenoid fossa, artiküler eminens, normal konumdaki artiküler disk ile anterior konumdaki artiküler diskin

segmentasyonları için YOLOv5 ve YOLOv8 mAP_0.5 değerleri Tablo 4.5'te verilmiştir.


Tablo 4.5 YOLOv5 ve YOLOv8 için mAP_0.5 değerleri

	YOLOv5 mAP_0.5 değeri	YOLOv8 mAP_0.5 değeri
Mandibular kondil	0.9950	0.99154
Artiküler eminens	0.945	0.95687
Glenoid fossa	0.721	0.811
Artiküler disk (normal konumda)	0.9950	0.97819
Artiküler disk (anteriora deplase)	0.86638	0.98965


Test veri setinde YOLOv5 ve YOLOv8 algoritmalarıyla yapılan tahminlere ait örnekler Şekil 4.21- 4.24'te gösterilmiştir.




Şekil 4.21: a. mandibular kondil segmentasyonu, b. YOLOv8'in mandibular kondil tahmini, c. artiküler eminens segmentasyonu, d. YOLOv8'in artiküler eminens tahmini, e. artiküler fossanın segmentasyonu, f. YOLOv8 modelinin artiküler fossa tahmini



Şekil 4.22: a. normal konumdaki artiküler diskin segmentasyonu, b. YOLOv8'in normal konumdaki artiküler disk tahmini, c. anteriora deplase artiküler diskin segmentasyonu, d. YOLOv8'in anteriora deplase artiküler disk tahmini



Şekil 4.23: a. mandibular kondil segmentasyonu, b. YOLOv5'in mandibular kondil tahmini, c. artiküler eminens segmentasyonu, d. YOLOv5'in artiküler eminens tahmini, e. artiküler fossanın segmentasyonu, f. YOLOv5 modelinin artiküler fossa tahmini



Şekil 4.24: a. normal konumdaki artiküler diskin segmentasyonu, b. YOLOv5'in normal konumdaki artiküler disk tahmini, c. anteriora deplase artiküler diskin segmentasyonu, d. YOLOv5'in anteriora deplase artiküler disk tahmini

5. TARTIŞMA

5.1 Gereç ve Yöntemler Tartışması

Temporomandibular eklem hastalıkları, TME'yi ve çevresindeki kas-iskelet sistemini etkileyen rahatsızlıkları kapsayan geniş bir hastalık grubudur. Bu hastalıklar, toplumda yaygın olarak görülen önemli bir halk sağlığı sorunudur ve orofasiyal bölgede dişsel kökenli olmayan kronik ağrı şikayetleri arasında en yaygın sebep olarak kabul edilmektedir [2, 151]. Valesan ve ark. [152] tarafından gerçekleştirilen bir sistematik derlemeye göre, genel TMEH prevalansı yetişkinler/yaşlılarda yaklaşık %31 ve çocuklar/ergenlerde %11 olarak belirlenmiştir. Ayrıca, TMEH arasında en yaygın görülen RDD olup yetişkinler/yaşlılarda yaklaşık %26 ve çocuklar/ergenlerde %7.5 oranında görülmüştür. Minervini ve ark. [153] tarafından çocuk ve ergenlerdeki TMEH prevalansının değerlendirilmesi amacıyla gerçekleştirilen sistematik derlemede, prevalansın %20 ile %60 arasında değişmekte olduğu belirlenmiştir. TMEH'nin genel popülasyondaki yüksek prevalansı göz önüne alındığında, çalışmamızda TME'ye ait anatomik landmarkların yapay zekâ ile çalışılması gelecekte yapılacak TMEH çalışmalarına rehberlik edecektir.

Temporomandibular eklem hastalıklarının klinik tanısı, karmaşık etiyolojik faktörler ve çeşitli semptomlar nedeniyle zordur ve bu nedenle görüntüleme yöntemleri tanıda önemli rol oynamaktadır. TME'nin kemik yapısındaki değişikliklerin değerlendirilmesi için KIBT veya BT tercih edilirken, MRG, yumuşak doku değişiklikleri ve internal disk bozukluklarının değerlendirmesinde kullanılır [154, 155]. TME hastalığının seyrinde, yumuşak dokular genellikle erken evrelerde etkilenirken, sert dokular daha sonraki evrelerde değişiklik göstermektedir [156]. Bu nedenle, erken evrelerin değerlendirilmesi için MRG uygunken, ileri evre TME hastalıklarının değerlendirilmesinde KIBT veya BT daha faydalıdır. Bu anlamda Jeon ve ark.'nın [157] çalışmasında klinik semptomları olan 325 hastanın KIBT ve MRG görüntüleri incelenmiş ve tüm klinik semptomlar (ses, ağrı ve sınırlı ağız açıklığı) için sadece MRG'de bulgu veren hasta sayısının, yalnızca KIBT'da bulgu veren hasta sayısından daha fazla olduğu tespit edilmiştir. Bu sonuçlar, semptomatik TME

hastaları için MRG'nin, KIBT'dan daha tercih edilebilir olabileceğini göstermektedir. Klinik semptomlar internal bozukluk, yumuşak doku veya hastalığın erken aşamaları ile ilişkili olduğunda, MRG'nin öncelikli olarak tercih edilmesi önerilmiştir. Ayrıca, hangi görüntüleme yönteminin daha uygun olduğu belirlenemediğinde, MRG birinci basamak görüntüleme yöntemi olarak önerilmiştir. Hara ve ark.'nın [158] juvenil idiopatik artrit hastalarının TME MRG, KIBT ve BT taramalarındaki görüntüleme bulgularını incelemek amacıyla yaptığı sistematik derlemede MRG'nin, TME'deki anormallikleri tespit etmede KIBT ve BT'den daha spesifik olduğu bildirilmiştir. Alarabawy ve ark.'nın [159] TME bozukluklarının değerlendirilmesinde MRG kriterlerini analiz etmek ve MRG'nin artroskopi ile karşılaştırıldığında önemli rolünü değerlendirmek amacıyla yaptığı çalışmada, MRG'nin artroskopiye kıyasla hassasiyeti %95, özgüllüğü %88 ve doğruluğu %94 olarak bulunmuştur. Pupo ve ark. [160] gerçekleştirdiği sistematik derlemede, erişkinlerdeki TME disk deplasmanı bozukluklarını tespit etmek için kullanılan Temporomandibular Bozukluklar için Araştırma Teşhis Kriterleri (RDC/TMD) gibi klinik muayene protokollerinin tanısal geçerliliği, altın standart olan MRG ile karşılaştırılmıştır. Bulgular, klinik muayene protokollerinin RDD ve RSDD tanısında MRG'ye kıyasla düşük duyarlılığa sahip olduğunu ve tanısal geçerliliğinin zayıf olduğunu göstermiştir. Klinik muayenenin disk-kondil ilişkisini değerlendirmede yetersiz kaldığı durumlarda ve elde edilen bilgilerin tedavi planını değiştirme potansiyeli bulunduğu, MRG'nin tercih edilmesi belirtilmiştir. Literatür bulgularına paralel olarak, TMEH tanısında MRG'nin daha etkili bir görüntüleme yöntemi olması sebebiyle çalışmamızda bu görüntüleme yöntemi tercih edilmiştir.

Manyetik rezonans görüntüleme, anterior disk deplasmanlarının teşhisi için en doğru ve temel tanı yöntemidir ancak önceki çalışmalar, uzman olmayan hekimlerin, hatta deneyimli uzmanların bile disk bozuklukları konusunda doğru MRG değerlendirmeleri yapamadığını ve TME MRG yorumlarının genellikle düşük tekrar edilebilirlik gösterdiğini ortaya koymuştur [6-8]. Butzke ve ark. [6] tarafından, yetişkin hastalara ait 30 TME MR inceleme, deneyimli ve eğitilmiş 9 gözlemci tarafından iki farklı zamanda bağımsız olarak yorumlanmıştır. Gözlemciler; TMEH ve orofasiyal ağrı alanında 2 yıllık yüksek lisans eğitimi almış ve MRG yorumlama eğitimi görmüş diş hekimleri, oral radyoloji alanında 2 yıllık yüksek lisans eğitimi almış ve TME MRG yorumlaması konusunda eğitim almış diş hekimleri ve tıp

radyolojisi alanında 3 yıllık yüksek lisans eğitimi almış tıp doktorlarından oluşmuştur. Bu gözlemcilerin, TME MRG yorumlamada en az 2 yıllık klinik deneyime sahip oldukları belirtilmiştir. Çalışma sonuçlarına göre, gözlemciler arası tekrarlanabilirlik düşük ile orta düzeyde değişiklik gösterirken, gözlemcilerin kendi içlerindeki tekrarlanabilirliği düşük veya hiç uyum göstermemiştir. Nebbe ve ark. [7]'nin çalışmasında adolesanlara ait 60 TME MR görüntüsü 3 oral ve maksillofasiyal radyolog ve bir ortodontist tarafından değerlendirilmiştir. Standartlaştırılmış sınıflandırma kriterlerini kullanarak deneyimli gözlemciler arasında tanımlanan tüm kategorilerde orta ile yüksek düzeyde gözlemci uyumu sağlanmıştır. Ancak, gözlemciler arası uyumun tüm disk pozisyonu kategorileri arasında eşit olmadığı belirlenmiştir. Gözlemciler, redüksiyonsuz tam disk deplasmanı olan eklemleri sınıflandırmada en yüksek uyumu göstermiştir, bunu redüksiyonlu tam disk deplasmanı ve normal disk pozisyonunu kategorize etmede orta ile yüksek düzeyde uyum takip etmiştir. Hafif ve orta düzeyde disk deplasmanlarının kategorize edilmesinde ise gözlemciler arasında daha zayıf bir uyum görülmüştür. Widmalm ve ark.'nın [8] çalışmasında, 34 hastanın TME MRG'leri, dört radyoloji uzmanı tarafından bağımsız olarak 13 belirli patolojik durum ve görüntü kalitesi açısından değerlendirilmiştir. Patolojik durumların tek tek gözlemciler tarafından yapılan değerlendirmelerinin karşılaştırıldığı 13 korelasyon katsayısından hiçbirisi iyi bulunmamış ve 8'i zayıf olarak değerlendirilmiştir. Bu sonuçlar, MRG'nin teşhis sürecinde önemli bir araç olduğunu, ancak doğru ve tutarlı yorumlamanın sağlanması için daha fazla eğitim ve standardizasyon geliştirilmesi gerektiğini ortaya koymaktadır. Literatür sonuçları doğrultusunda mevcut çalışmada standardizasyon geliştirmek ve doğru tanıya daha hızlı ulaşmak adına TME MR görüntü değerlendirilmesi yapay zekayla çalışılmıştır. Yapay zekanın TME bölgesini tanıyıp analiz etmesi, görüntülerin yorumlanmasında ortaya çıkabilecek subjektif farklılıkları en aza indirerek daha tutarlı ve standardize edilmiş sonuçlar elde edilmesine katkıda bulunabilir. Bu tür sistemler, belirli kriterler çerçevesinde sürekli olarak aynı analiz yöntemlerini uygulayarak daha güvenilir, hızlı ve tekrarlanabilir sonuçlar sağlamaktadır. Bu tez çalışmasında, MRG yorumlamasında standardizasyon sağlamak amacıyla derin öğrenme teknikleri kullanılmıştır.

Literatürde derin öğrenme tabanlı yapay zekâ modelleri ile TME segmentasyonu veya anterior disk deplasmanının tespit edildiği sınırlı sayıda çalışma

mevcuttur. Nozawa ve ark. [161] 2021 yılında ağız açık ve ağız kapalı pozisyonlarda alınan 1200 sagittal MR görüntüsü üzerinden artiküler diskin otomatik segmentasyonu için bir derin öğrenme modeli oluşturmuştur. Lin ve ark. [162] 2021 yılında TME'ye ait 9009 adet sagittal MR görüntüsünü kullanarak anterior disk deplasmanını tespit etmeye çalışmıştır. Li ve ark. [163] 2022 yılında 140 hastadan (280 TME) alınan 2.614 MR görüntüsü üzerinde mandibular kondil, artiküler eminens ve artiküler diski segmente etmiştir. Ito ve ark. [164] 2022 yılında toplamda 217 proton yoğunluğu ağırlıklı sagittal görüntü kullanarak artiküler diski segmente etmiştir. Yoon ve ark. [165] 2024 yılında 542 hastadan elde edilen 3693 MR görüntüsünden oluşan bir veri seti kullanarak temporal kemik, disk ve kondil gibi TME bileşenlerinin otomatik segmentasyonuna yönelik derin öğrenme modelleri geliştirmiştir. Lee ve ark. [166] 2022 yılında 2520 sagittal TME MR görüntüsü üzerinden anterior disk deplasmanını tespit etmeye çalışmıştır. Li ve ark. [167] 2024 yılında 668 sagittal TME MR görüntüsü kullanarak anterior disk deplasmanlarını tespit etmeye çalışmışlardır. Mevcut çalışma kapsamında, toplam 901 adet T2 ağırlıklı sagittal MR görüntüsü kullanılarak, yapay zekâ tabanlı nesne tespit yöntemlerinden YOLOv5 ve YOLOv8'in, TME'yi oluşturan anatomik yapıların segmentasyonundaki performansı ve anterior disk deplasmanını tespit etmedeki başarısı değerlendirilmiştir. Bu çalışma ile mevcut bilgi birikimini zenginleştirerek yeni perspektifler sunulmaya çalışılmıştır.

Literatürde farklı birçok mimari kullanılmıştır. Bunlardan Nozawa ve ark.'nın [161] artiküler diskin segmentasyonu için yaptıkları çalışmada CNN olarak modifiye edilmiş bir U-Net modeli kullanılmıştır. Li ve ark. [163] yaptığı çalışmada üç anatomik yapının (mandibular kondil, artiküler eminens ve artiküler diski) segmentasyonu için iki farklı CNN (UNet++ ve nn-UNet) kullanmıştır. Çalışmada 2D ve 3D segmentasyon yapılmıştır. UNet++ 2D segmentasyon için kullanılırken, nn-UNet 3D segmentasyon için kullanılmıştır. Ito ve ark. [164] çalışmasında, artiküler disk 3 farklı model ile (3DiscNet, U-Net ve SegNet-Basic) segmente edilmiştir. Lin ve ark. [162] MRG kullanarak anterior disk deplasmanını otomatik olarak teşhis edebilen CNN tabanlı bir derin öğrenme modeli geliştirmeye çalışmıştır. Derin öğrenme modelleri, ResNet mimarisine ve "Imagenet" veri tabanına dayalı bir CNN kullanılarak geliştirilmiştir. Yoon ve ark. [165] temporal kemik, artiküler disk ve mandibular kondilin otomatik segmentasyonunu sağlayan derin öğrenme modelleri geliştirmiştir. DeepLabV3Plus, ResNet101 ile OCRNet, ResNet101 ile UPerNet, Swin Transformer ile birleştirilmiş

UPerNet ve Segformer modelleri kullanılmıştır. Lee ve ark.'nın [166] anterior disk deplasmanlarını tespit etmek için yaptıkları çalışmada görüntü sınıflandırması için CNN mimarilerinden VGG16 kullanılmıştır. Li ve ark. [167], ResNet152 CNN modeli anterior disk deplasmanlarını tespit etmeye çalışmışlardır. Çalışmamızda YOLOv5 ve YOLOv8 modelleri kullanılmış olup, nesne tespit yöntemleri içinde hızı ve yüksek doğruluğu vaat etmesi ve literatürdeki eksiklik nedeniyle YOLO algoritmaları tercih edilmiştir. YOLOv5 ve YOLOv8 algoritmalarının performans karşılaştırmaları ise bu yöntemlerin TME segmentasyonundaki doğrulukları ile disk deplasmanını saptama yeteneklerini değerlendirmek amacıyla yapılmıştır. YOLO algoritması, tanıtıldığı tarihten bu yana hızı ve doğruluğuyla nesne tespit algoritmaları içinde popülerlik kazanmıştır [168].

Medikal görüntülemelerde YOLO algoritmasının kullanıldığı çalışmaları incelediğimizde, 2024 yılında Almufareh ve ark. [169] tarafından yapılan çalışmada, 827 MR görüntüsünden oluşan bir veri seti ile derin öğrenme modellerinin beyin tümörü tespiti ve sınıflandırmasındaki performansı değerlendirilmiştir. Bu çalışmada YOLOv5 ve YOLOv7 modelleri kullanılmıştır. YOLOv5, 0.936 kesinlik, 0.906 duyarlılık ve %0.5 IoU eşiğinde 0.947 mAP skorları elde ederken, YOLOv7 de benzer şekilde 0.935 kesinlik, 0.903 duyarlılık ve %0.5 IoU eşiğinde 0.947 mAP değerlerine ulaşmıştır. Her iki model de, spesifik tümör sınıflarının doğru bir şekilde segmentasyonu ve tanımlanmasında üstün performans göstermiştir. 2024 yılında, Yaseen ve ark.'nın [170] servikal omurları tespit etmek için geliştirdikleri YOLOv5 tabanlı model, servikal omurların BT taramaları ile kemik yapılarını tanıyacak ve yerini belirleyecek şekilde eğitilmiştir. Bu model, %0.5 IoU eşiğinde 0.93 mAP skorları elde etmiş olup, YOLOv5 mimarisinin servikal omurları doğru bir şekilde tespit etme ve yerini belirleme konusundaki yüksek performansını göstermektedir. Bu bulgular, YOLO algoritmalarının medikal görüntülemelerde, nesne tespitinde yüksek doğruluk sağlama potansiyelini ortaya koymaktadır. Bu tür yüksek performanslı algoritmalar, klinik uygulamalarda tanı doğruluğunu artırabilir ve tedavi süreçlerinin optimize edilmesine katkıda bulunabilir. Çalışmamızda da medikal görüntüleme alanında nesne tespitinde hız, yüksek doğruluk ve yüksek mAP değerleri sağlama potansiyeli nedeniyle YOLOv5 ve YOLOv8 modelleri tercih edilmiştir.

5.2 Bulguların Tartışılması

Segmentasyon ve sınıflandırma modellerinin performansını değerlendirirken, DP, YP ve YN değerleri kritik öneme sahiptir. DP, modelin doğru bir şekilde tespit ettiği hedef bölgeleri veya sınıfları temsil eder ve modelin genel başarısını gösterir. YP, modelin yanlış bir şekilde tespit ettiği pozitif sonuçları ifade eder; bu tür hatalar, modelin fazladan sınıflandırma yaptığı anlamına gelir ve uygulama alanına göre problematik olabilir. YN ise, modelin tespit etmesi gereken bir hedefi veya sınıfı gözden kaçırdığı durumları gösterir. Yüksek YN değerleri, modelin önemli verileri gözden kaçırdığını ve bu nedenle doğruluğunun düştüğünü gösterir. DP, YP ve YN değerlerinin dengeli olması, bir modelin hem hassasiyetini hem de kesinliğini doğru şekilde yansıtması açısından büyük önem taşımaktadır [171]. 2023 yılında Eşer ve ark. [172] tarafından, yapay zekâ ile KIBT sagittal görüntüleri üzerinden TME segmentasyonu ve osteoartrit sınıflandırması yapılan çalışmada, YOLOv5 modelinin mandibular kondil segmentasyonu için DP, YP ve YN değerleri sırasıyla; 215, 1 ve 0 şeklinde bulunmuştur. Çalışmamızda ise mandibular kondil segmentasyonunda, YOLOv5 modeli 90 DP, 1 YP ve 0 YN sonuç üretmiştir. YOLOv8 modeli ise 89 DP, 2 YP ve 1 YN sonuç göstermiştir. Artiküler eminens segmentasyonunda, YOLOv5 modeli 89 DP, 3 YP ve 1 YN sonuç üretirken YOLOv8 modeli 89 DP, 1 YP ve 1 YN sonuç göstermiştir. Glenoid fossa segmentasyonunda, YOLOv5 modeli 73 DP, 8 YP ve 15 YN sonuç göstermiştir. YOLOv8 modeli ise 85 DP, 1 YP ve 3 YN sonuç üretmiştir. Normal konumdaki artiküler disk segmentasyonunda, YOLOv5 modeli 63 DP, 0 YP ve 0 YN sonuç göstermiştir. YOLOv8 modeli ise 62 DP, 0 YP ve 1 YN sonuç üretmiştir. Anterior konumdaki artiküler disk segmentasyonunda, YOLOv5 modeli 26 DP, 1 YP ve 0 YN sonuç üretmiştir. YOLOv8 modeli ise 25 DP, 4 YP ve 1 YN sonuç göstermiştir. Eşer ve ark. [172] tarafından 2023 yılında yapılan çalışmada, TME'ye ait anatomik bileşenlerden sadece mandibular kondil 2000 adet sagittal KIBT görüntüsü üzerinden segmente edilmiştir ve YOLOv5 modelindeki sonuçların mandibular kondil segmentasyonunda son derece başarılı olduğu, YP ve YN oranlarının neredeyse sıfır olduğu gösterilmiştir. Bu da modelin çok yüksek hassasiyete sahip olduğunu işaret eder. Bulgularımız Eşer ve ark. [172] ile paralel olarak son derece başarılı bulunmuştur. Her iki çalışma incelendiğinde, YOLOv5 modelinin segmentasyon görevlerinde oldukça yüksek doğruluk sağladığı ve düşük YP ve YN değerleriyle güçlü bir performans sergilediği görülmektedir. YOLOv8

modeli ise bazı segmentasyon görevlerinde daha düşük YP ve YN değerleri sunarak belirli durumlarda daha yüksek doğruluk sağlasa da, genel olarak YOLOv5'e kıyasla daha fazla hata yapma eğilimindedir.

Literatürde, model performansını ölçmek için kullanılan metriklerden bazıları duyarlılık, kesinlik ve F1 skorudur. Bu metrikleri kullanan çalışmalardan, Nozawa ve ark.'nın [161] çalıştığı veri seti, iki farklı hastanenin verilerinden (Hastane A ve Hastane B) oluşmaktadır. Bu veri setinde TMEH olan 357 hastaya ait (600 TME) kapalı ve açık ağız pozisyonunda toplam 1200 MR görüntüsü bulunmaktadır. Bu görüntüler üzerinden artiküler diskin segmentasyonu gerçekleştirilmiştir. Hastane A'dan elde edilen 1000 görüntünün 800'ü eğitim ve doğrulama verileri olarak kullanılmıştır. Hastane A'dan kalan 200 görüntü, dahili test verileri olarak kullanılırken Hastane B'den alınan 200 görüntünün tamamı yalnızca harici test verisi olarak kullanılmıştır. Çalışmada CNN olarak modifiye edilmiş bir U-Net kullanılmıştır. Normal pozisyonundaki diskin Hastane A'dan alınan test verilerinde duyarlılık değeri 0.953, kesinlik değeri 0.897, F1 skoru 0.923; Hastane B'den alınan test verilerinde duyarlılık değeri 0.879, kesinlik değeri 0.907, F1 skoru 0.892; totalde de duyarlılık değeri 0.916, kesinlik değeri 0.902, F1 skoru 0.908 olarak bulunmuştur. Anterior pozisyonundaki diskin Hastane A'dan alınan test verilerinde duyarlılık değeri 0.989, kesinlik değeri 0.771, F1 skoru 0.867; Hastane B'den alınan test verilerinde duyarlılık değeri 0.87, kesinlik değeri 0.899, F1 skoru 0.884; totalde de duyarlılık değeri 0.929, kesinlik değeri 0.826, F1 skoru 0.875 olarak bulunmuştur. Çalışmamızda ise normal konumdaki artiküler diskin YOLOv5 modelindeki duyarlılık değeri 1, kesinlik değeri 1, F1 skoru 1; YOLOv8 modelindeki duyarlılık değeri 0.98, kesinlik değeri 1, F1 skoru 0.99 olarak bulunmuştur. Anterior konumdaki artiküler diskin YOLOv5 modelindeki duyarlılık değeri 1, kesinlik değeri 0.96, F1 skoru 0.98; YOLOv8 modelindeki duyarlılık değeri 0.96, kesinlik değeri 0.86, F1 skoru 0.90 olarak bulunmuştur. Çalışmamızda kullanılan YOLOv5 ve YOLOv8 modelleri, normal pozisyonundaki disk segmentasyonunda mükemmel performans sergilemiştir. Sonuç olarak, hem normal pozisyonundaki hem de anterior pozisyonundaki artiküler disk segmentasyonunda YOLOv5 ve YOLOv8 modellerimiz, Nozawa ve ark.'nın [161] çalışmalarına kıyasla daha yüksek duyarlılık, kesinlik ve F1 skorları sunmaktadır. Çalışma sonuçlarındaki farklılık, genel olarak Nozawa ve ark. [161]'nın farklı

örneklem sayısı ile çalışması, farklı mimari kullanması ve çalışmanın çok merkezli olması ile açıklanabilir.

2023 yılında Kao ve ark.'nın [173] anterior disk deplasmanını teşhis edebilen bir yapay zekâ modeli geliştirmek amacıyla gerçekleştirdiği çalışmada, temporal kemik ve mandibular kondil arasındaki eklem boşluğunu tespit etmek için U-net mimarisi kullanılmıştır. Çalışmada, 100 sagittal MR görüntüsü ile ilgilenilen bölgenin (ROI) sınıflandırılması sağlanmıştır. Modelin performansını değerlendirmek için dört farklı CNN mimarisi uygulanmıştır: InceptionResNetV2, InceptionV3, DenseNet169 ve VGG16. Elde edilen sonuçlar doğrultusunda, InceptionV3 ve DenseNet169 mimarileri en yüksek performansı sergilemiştir. InceptionV3'ün duyarlılık, kesinlik ve F1 skoru sırasıyla 1, 0.81 ve 0.9 olarak bulunmuştur. DenseNet169 modelinin ise sırasıyla 0.92, 0.86 ve 0.89 değerlerine ulaşmıştır. Bu sonuçlar, her iki modelin de anterior disk deplasmanının teşhisinde etkili olduğunu ve klinik uygulamalar için potansiyel taşıdığını göstermektedir. Çalışmamızda ise anterior konumdaki artiküler diskin YOLOv5 modelindeki duyarlılık değeri 1, kesinlik değeri 0.96, F1 skoru 0.98; YOLOv8 modelindeki duyarlılık değeri 0.96, kesinlik değeri 0.86, F1 skoru 0.90 olarak bulunmuştur. Anterior disk deplasmanının tespit edilmesinde mevcut çalışmanın bulguları Kao ve ark. [173]'nın sonuçları ile paralel olmakla birlikte YOLOv5'in yüksek kesinlik ve F1 skorları ile dikkat çektiği ve mevcut diğer modellere göre en yüksek performansı sergilediği görülmektedir. Bulgularımızın Kao ve ark.'nın [173] çalışmalarına kıyasla daha yüksek duyarlılık, kesinlik ve F1 skorları göstermesi, daha fazla örneklem sayısı ile çalışılması, farklı mimari kullanımı ile açıklanabilir.

2023 yılında Eşer ve ark. [172] tarafından yapılan çalışmada, YOLOv5 modelinin mandibular kondil segmentasyonu için duyarlılık, kesinlik ve F1 skorları sırasıyla; 1, 0.99 ve 0.99 şeklindedir. Çalışmamızda, mandibular kondil segmentasyonunda, YOLOv5'in duyarlılığı 1 iken, YOLOv8'in duyarlılığı 0,98'dir. YOLOv5'in kesinlik değeri 0,98, YOLOv8'in kesinlik değeri ise 0,97'dir. F1 skoru açısından, YOLOv5 0,99, YOLOv8 ise 0,98 değerlerine sahiptir. Artiküler eminens segmentasyonunda ise hem YOLOv5 hem de YOLOv8'in duyarlılık değerleri 0,98 olarak ölçülmüştür. Kesinlik açısından, YOLOv5 0,96, YOLOv8 ise 0,98 olarak hesaplanmıştır. F1 skoru, YOLOv5 için 0,97, YOLOv8 için ise 0,98'dir. Glenoid fossa segmentasyonunda YOLOv5'in duyarlılığı 0,82, YOLOv8'in duyarlılığı ise 0,96'dır.

Kesinlik değeri YOLOv5 için 0,90, YOLOv8 için ise 0,98'dir. F1 skoru ise YOLOv5 için 0,86, YOLOv8 için 0,97'dir. Bulgularımız, Eşer ve ark.'nın [172] bulgularıyla paralel olup, minör farklılıklar mevcuttur. Bu durum, örneklem sayısının farklılığı ve görüntüleme yöntemi farklılığı ile açıklanabilir. YOLOv5 modelinin performansının oldukça yüksek olduğu ve YOLOv8'in performansının buna yakın seviyede olduğu görülmektedir.

Yoon ve ark.'nın [165] 542 hastadan elde edilen 3693 MR görüntüsünden oluşan bir veri seti kullanarak temporal kemik, disk ve kondil gibi TME bileşenlerinin otomatik segmentasyonunu yaptıkları çalışmada, temporal kemik için DeepLabV3plus modelinin duyarlılığı 0.892, UPerNet-Swin modelinin duyarlılığı 0.897, UPerNet-resnet101 modelinin duyarlılığı 0.882, OCRNet modelinin duyarlılığı 0.886, SegFormer modelinin duyarlılığı ise en yüksek değere ulaşarak 0.912 olarak belirlenmiştir. Disk için duyarlılık değerleri, DeepLabV3plus modelinde 0.753, UPerNet-Swin modelinde 0.750, UPerNet-resnet101 modelinde 0.760, OCRNet modelinde 0.755, SegFormer modelinde 0.749 olarak belirlenmiştir. Kondil segmentasyonu için, DeepLabV3plus modelinde 0.922, UPerNet-Swin modelinde 0.924, UPerNet-resnet101 modelinde 0.914, OCRNet modelinde 0.915, SegFormer modelinde 0.938 duyarlılık değerleri elde edilmiştir. Ito ve ark.'nın [164] toplamda 217 proton yoğunluğu ağırlıklı sagittal görüntü kullanarak artiküler diski segmente ettiği çalışmada, normal konumdaki artiküler diskin ortalama duyarlılık değerleri, 3DiscNet için 0.73, U-Net için 0.40, SegNet-basic için 0.70 olarak bulunmuştur. Anterior konumdaki artiküler diskin ortalama duyarlılık değerleri, 3DiscNet modelinde 0.72, U-Net modelinde 0.28, SegNet-basic modelinde 0.64 olarak belirlenmiştir. Mevcut çalışma, özellikle disk ve kondil segmentasyonunda YOLOv5 modelinin gösterdiği 1 duyarlılık değeri ile Yoon ve ark.'nın [165] bulgularından daha yüksek bir performans sergilemektedir. Çalışmamız, Ito ve ark.'nın [164] çalışmasına kıyasla disk segmentasyonu konusunda daha yüksek duyarlılık değerleri sunmaktadır. Özellikle YOLOv5'in sağladığı mükemmel sonuçlar, mevcut literatürdeki en yüksek performansları temsil etmektedir.

Literatürde YOLO mimarisi kullanılarak yapılan birçok çalışma vardır. Bunlardan YOLOv8'in yeni bir sürüm olması nedeniyle, YOLOv5 ve YOLOv8'i doğrudan karşılaştıran çalışmaların sınırlı olduğu görülmektedir. Taşsöker ve ark.'nın [174] 2024 yılında, 1068 hastanın panoramik görüntüleri üzerinde TME

dejenerasyonunu tespit etmek amacıyla yaptıkları çalışmada, YOLOv5, YOLOv7 ve YOLOv8 algoritmaları karşılaştırılmıştır. YOLOv5, 0.9440 doğruluk, 0.8163 kesinlik, 0.8696 duyarlılık, 0.8421 F1 skoru elde etmiştir. YOLOv7, 0.9963 doğruluk, 0.9787 kesinlik, 1 duyarlılık, 0.9892 F1 skoru ile en başarılı sonuçları sağlamıştır. YOLOv8 ise 0.9664 doğruluk, 0.9111 kesinlik, 0.8913 duyarlılık, 0.9011 F1 skoru ile genel olarak YOLOv5'in üzerinde performans sergilemiş, ancak YOLOv7'nin sonuçlarına ulaşamamıştır. YOLOv8'in doğruluk ve kesinlik açısından YOLOv5'e üstünlük sağladığı, ancak duyarlılık bakımından iki algoritmanın birbirine yakın olduğu gözlenmiştir. Fitria ve ark.'nın [175] 2024 yılında 294 adet ağız içi fotoğraf üzerinden çürük, eksik ve dolgulu dişleri tespit edebilen bir model geliştirmeyi amaçladıkları çalışmada, YOLOv5 ve YOLOv8 mimarilerinin varyasyonları kullanılarak model doğrulukları karşılaştırılmıştır. En yüksek performans gösteren varyantlar YOLOv5l ve YOLOv8m olarak bulunmuştur. YOLOv5l'nin kesinlik değeri 0.97, duyarlılık değeri 0.85, mAP değeri 0.904 iken YOLOv8m'nin kesinlik değeri 0.95, YOLOv8m'nin duyarlılık değeri 0.84, mAP değeri ise 0.906'dır. YOLOv5l ve YOLOv8m kıyaslandığında, YOLOv5l'nin yüksek kesinlik ve duyarlılık değerleri ile daha verimli bir model olduğu, YOLOv8m'in ise az bir farkla daha yüksek mAP değeri sağladığı gözlenmiştir. Bonfanti-Gris ve ark. [176] 600 adet panoramik radyografiden oluşan bir veri setinde, önemli anatomik yapılara ve tedavilere ilişkin nesne tespiti ve segmentasyon açısından üç derin öğrenme tabanlı CNN modelinin tanısallık performansını değerlendirmişlerdir. YOLOv5, YOLOv7 ve YOLOv8 versiyonlarının karşılaştırıldığı çalışmada, YOLOv5s'nin duyarlılığı 0.634, kesinliği 0.781 ve mAP_0.5 değeri 0.631'dir. YOLOv7m, 0.793 duyarlılık, 0.779 kesinlik ve 0.740 mAP_0.5 değerleri ile en iyi nesne tespit sonuçlarını elde etmiştir. YOLOv8m'nin ise duyarlılığı 0.743, kesinliği 0.757 ve mAP_0.5 değeri 0.708 olarak bulunmuştur. Segmentasyonda ise YOLOv5s kıyaslanamayacak kadar düşük sonuçlar vermiştir. YOLOv8m 0.6083 kesinlik ile YOLOv7'nin 0.5775 kesinlik değerinden daha yüksek sonuçla segmentasyonda en başarılı model olmuştur. Çalışmamızda, mandibular kondil segmentasyonunda, YOLOv5 modelindeki duyarlılık 1, kesinlik değeri 0,98, F1 skoru 0,99'dur. YOLOv8'in duyarlılığı 0,98, kesinliği 0,97, F1 skoru ise 0,98 değerlerine sahiptir. Artiküler eminens segmentasyonunda ise hem YOLOv5 hem de YOLOv8'in duyarlılık değerleri 0,98 olarak ölçülmüştür. Kesinlik açısından, YOLOv5 0,96, YOLOv8 ise 0,98 olarak hesaplanmıştır. F1 skoru, YOLOv5 için 0,97, YOLOv8 için ise 0,98'dir. Glenoid fossa segmentasyonunda YOLOv5'in duyarlılık değeri 0,82,

kesinlik değeri 0,90, F1 skoru ise 0,86 olarak bulunmuştur. YOLOv8'in duyarlılığı ise 0,96, kesinliği 0,98, F1 skoru 0,97'dir. Normal konumdaki artiküler diskin YOLOv5 modelindeki duyarlılık değeri 1, kesinlik değeri 1, F1 skoru 1; YOLOv8 modelindeki duyarlılık değeri 0.98, kesinlik değeri 1, F1 skoru 0.99 olarak bulunmuştur. Anterior konumdaki artiküler diskin YOLOv5 modelindeki duyarlılık değeri 1, kesinlik değeri 0.96, F1 skoru 0.98; YOLOv8 modelindeki duyarlılık değeri 0.96, kesinlik değeri 0.86, F1 skoru 0.90 olarak bulunmuştur. Çalışmamızda YOLOv5 mandibular kondil ve artiküler disk segmentasyonlarında duyarlılık açısından %100 performans sergilemiştir. Ayrıca glenoid fossa segmentasyonu hariç, yüksek kesinlik ve F1 skorları göstermiştir. YOLOv8, glenoid fossa ve artiküler eminens segmentasyonlarında YOLOv5'e göre daha dengeli sonuçlar vermiştir. Sonuç olarak YOLOv5, duyarlılık gerektiren segmentasyon görevlerinde daha başarılı olurken, YOLOv8 bazı segmentasyonlarda kesinlik açısından avantaj sağlamaktadır. Hangi modelin seçileceği, belirli bir görevde hangi metriğin (duyarlılık, kesinlik veya F1 skoru) daha önemli olduğuna bağlıdır. Taşsöker ve ark.'ndan [174] farklı olarak çalışmamızda YOLOv5 modelinin genel olarak daha başarılı olduğu söylenebilir. Ancak, YOLOv8'in özellikle glenoid fossa segmentasyonunda sağladığı yüksek performans da göz önünde bulundurulmalıdır. Dolayısıyla, her iki modelin de belirli uygulamalarda üstün performans sağlayabileceği görülmektedir. Fitria ve ark.'nın [175] çalışmasına benzer şekilde çalışmamızda YOLOv5 daha başarılı sonuçlar göstermiştir. Bonfanti-Gris ve ark.'ndan [176] farklı olarak YOLOv5 modeli segmentasyonda oldukça başarılı sonuçlar vermiştir. Bu, kullanılan veri seti farklılığı, eğitim sürecinde kullanılan veri artırma teknikleri, öğrenme oranı, eğitim süresi gibi faktörler, YOLOv5'in farklı versiyonlarının kullanılmış olması gibi değişikliklerden kaynaklı olabilir.

Nesne tespit modellerini değerlendirmek için derin öğrenmede en çok kullanılan metriklerden biri mAP değeridir. mAP değeri her sınıf için hesaplanan AP değerlerinin ortalamasını ifade etmektedir. AP ise PR eğrisinin altındaki alanı hesaplayarak modelin kesinlik ve duyarlılık performansını özetleyen tek bir değer sağlar. Literatürde mAP değerini performans değerlendirmek için kullanan çalışmalar mevcuttur. Yoon ve ark.'nın [177] 2023 tarihli iki derin öğrenme modeline dayanan çalışmasında, ilk model, tüm sagittal MR görüntülerinde temporal kemik, disk ve kondili içeren ROI'yi tespit eder. İkinci derin öğrenme modeli ise tespit edilen bu ROI

içinde TME diskini normal, RSDD ve RDD olarak sınıflandırmaktadır. İlk derin öğrenme modelinin TME yapılarını içeren ROI'yi tespit etme performansını değerlendirmek için mAP kullanılmıştır ve 0.75 IoU eşik değerinde 0.819 mAP değerine ulaşılmıştır. Elaziz ve ark.'nın [178] 2024 yılında yayınladıkları çalışmada 3000 adet panoramik görüntü üzerinden kondil bölgesi YOLOv8 modeli ile tespit edilmiştir. Mandibular kondil bölgelerini tespit etmede YOLOv8'in mAP_0.5 skoru, sağ ve sol taraflar için sırasıyla 0.918 ve 0.913 değerlerine ulaşmıştır. Taşşöker ve ark.'nın [174] kondil dejenerasyonunu tespit etmek amacıyla yaptıkları çalışmada mAP_0.5 değerleri YOLOv5 için 0.989, YOLOv7 için 0.988, YOLOv8 için 0.955 olarak bulunmuştur. Mevcut çalışmada, mandibular kondil için YOLOv5 mAP_0.5 değeri 0.9950, YOLOv8 mAP_0.5 değeri 0.99154'tür. Artiküler eminens için YOLOv5 mAP_0.5 değeri 0.945, YOLOv8 mAP_0.5 değeri 0.95687'dir. Glenoid fossa için YOLOv5 mAP_0.5 değeri 0.721, YOLOv8 mAP_0.5 değeri 0.811'dir. Artiküler disk (normal konumda) için YOLOv5 mAP_0.5 değeri 0.9950, YOLOv8 mAP_0.5 değeri 0.97819'dur. Artiküler disk (anteriora deplase) için YOLOv5 mAP_0.5 değeri 0.86638, YOLOv8 mAP_0.5 değeri 0.98965'tir. Çalışmamızda glenoid fossa segmentasyonu hariç Yoon ve ark.'nın [177] çalışmasından daha yüksek mAP değerleri bulunmuştur ancak bu durum, farklı IoU eşik değerinde çalışılması kaynaklı olabilir. Glenoid fossa segmentasyonundaki düşük mAP değerleri, bu yapının tespitinin diğer anatomik bölgelerden daha zorlu olmasından kaynaklanmış olabilir. Çalışmamızın mandibular kondil segmentasyonunda mAP değeri 0.99154 olup Elaziz ve ark.'nın [178] sonuçlarından daha yüksek başarı elde edildiği görülmüştür. Bu durum, farklı görüntüleme yöntemi kullanılması ve örneklem sayısının farklılığı ile açıklanabilir. Mevcut çalışma, kondil segmentasyonunda hem YOLOv5 hem de YOLOv8'de Taşşöker ve ark.'nın [174] çalışmasına kıyasla daha yüksek mAP_0.5 değerleri elde etse de iki çalışma için de sonuçlar oldukça başarılıdır.

Çalışmamızın başlıca limitasyonları şu şekilde özetlenebilir:

Çalışmamıza ait veri seti tek merkeze ait arşiv kayıtlarından elde edilmiştir. Veri setini oluşturan tüm MRG taramaları Bezmialem Vakıf Üniversitesi Tıp Fakültesi Radyoloji bölümünde gerçekleştirilmiştir. Çok merkezli bir veri seti ile değerlendirme, yanlışlıkları azaltarak modelin daha objektif sonuçlar üretmesini sağlayabilir. Ayrıca daha geniş bir yelpazede geçerliliği sağladığından model klinik uygulama için daha uygun hale gelebilir.

Manyetik rezonans görüntülerinin kalitesi ve çözünürlüğü, segmentasyon sonuçlarını etkileyebilir. Düşük kaliteli veya yüksek miktarda gürültü içeren görüntüler, modelin performansını sınırlayabilirken, 3 Tesla gibi daha yüksek manyetik alan gücü olan MR cihazları ile alınan yüksek kaliteli görüntüler model performansını artırabilir. Çalışmamızda 1.5 Tesla MR cihazı ile görüntü elde edilmiştir. İlerleyen dönemde yapılacak çalışmalarda daha yüksek kalitede görüntülere sahip bir veri seti kullanılabilir.

Çalışma tasarımı retrospektif olarak planlandığından MR görüntülerine ait ham data setlerine ulaşamamıştır. Bu da etiketleme için görüntülerin DICOM seti şeklinde yüklenememesine sebep olmuştur. Görüntüler 2D sagittal kesitler şeklinde yüklenebildiğinden patoloji değerlendirmelerinden sadece anteriora deplase diskin segmentasyonu yapılabilmektedir.

6. SONUÇLAR

Bu çalışmada, yapay zekâ destekli Craniocatch (Eskişehir, Türkiye) uygulaması kullanılarak, T2 ağırlıklı sagittal MR görüntüleri üzerinden, TME yapısal bileşenlerinin; mandibular kondil, artiküler eminens, glenoid fossa ve artiküler diskin segmentasyonu gerçekleştirilmiştir. Artiküler disk hem normal konumda hem de anteriora deplase konumda segmente edilmiştir. Aynı zamanda, YOLOv5 ve YOLOv8 modelleri karşılaştırmalı olarak değerlendirilmiştir.

Çalışmamızın sonuçları:

- Mandibular kondil segmentasyonunda, YOLOv5 modeli için duyarlılık 1, YOLOv8 modeli için duyarlılık 0.98 olarak bulunmuştur. YOLOv5 modeli için kesinlik 0.98 olup, çok yüksek bir doğruluk oranı göstermiştir. YOLOv8 modeli için kesinlik 0.97 ile YOLOv5'e kıyasla biraz daha düşüktür. YOLOv5'in F1 skoru 0.99 ile mükemmele yakınken YOLOv8'in F1 skoru 0.98'dir. YOLOv8 çok az farkla daha düşük sonuçlar verse de her iki modelde mandibular kondil segmentasyonunda yüksek başarı göstermiştir.
- Artiküler eminens segmentasyonunda, YOLOv5 ve YOLOv8 modelleri için duyarlılık her iki modelde de 0.98'dir. YOLOv5'in kesinliği 0.96 iken YOLOv8 modeli için kesinlik 0.98 olup YOLOv8, YOLOv5'e kıyasla daha iyi performans göstermiştir. YOLOv5'in F1 skoru 0.97, YOLOv8'in F1 skoru ise 0.98'dir. YOLOv5 çok az farkla daha düşük sonuçlar verse de her iki modelde artiküler eminens segmentasyonunda yüksek başarı göstermiştir.
- Glenoid fossa segmentasyonunda, YOLOv5 için duyarlılık 0.82, YOLOv8 için duyarlılık ise 0.96'dır. YOLOv8, YOLOv5'e göre belirgin bir üstünlük sağlamıştır. YOLOv5 için kesinlik 0.90, YOLOv8 için ise 0.98'dir. YOLOv8 bu metrikte de daha yüksek performans göstermiştir. YOLOv5'in F1 skoru 0.86 iken, YOLOv8'in F1 skoru 0.97 ile çok daha üstündür.
- Normal konumda olan artiküler diskin segmentasyonunda, YOLOv5 için duyarlılık 1'dir yani model tüm doğru pozitifleri tespit etmiştir. YOLOv8 modeli için duyarlılık 0.98 olup, YOLOv5'e göre biraz daha düşük bir

performans sergilemiştir. YOLOv5 ve YOLOv8 için kesinlik 1 olup, her iki model de doğru tespitlerinde yüksek doğruluk sağlamıştır. YOLOv5'in F1 skoru 1 ile mükemmeldir. YOLOv8'in F1 skoru 0.99 ile YOLOv5'e çok yakın bir performans göstermektedir.

- Anterior konumda olan artiküler diskin segmentasyonunda, YOLOv5 için duyarlılık 1, yani model anterior konumdaki tüm diskleri doğru şekilde tespit etmiştir. YOLOv8'in duyarlılığı 0.96 olup, YOLOv5'e göre biraz daha düşük kalmıştır. YOLOv5 için kesinlik 0.96 olup, oldukça yüksek bir doğruluk göstermektedir. YOLOv8'in kesinliği 0.86 ile YOLOv5'e kıyasla daha düşük performans sergilemiştir. YOLOv5'in F1 skoru 0.98 ile oldukça başarılıdır. YOLOv8'in F1 skoru 0.90 olup, YOLOv5'e göre daha düşük bir sonuç göstermiştir.

Yapay zekâ modeliyle MR görüntüleri üzerinden TME bölgesini segmente ettiğimiz bu çalışmanın sonuçları umut vericidir. Çalışmada eğitilen YOLOv5 ve YOLOv8 modellerinin hem TME yapısal bileşenlerinin hem de anteriora deplase diskin segmentasyonu için elde ettiği sonuçlar oldukça başarılıdır.

Elde edilen sonuçlar yapay zekâ destekli sistemlerin klinik ve radyoloji rutinde hekimlere teşhis için kolaylık ve zaman kazandıracak destek mekanizması olabileceği yönündedir. TMEH gibi toplumda oldukça yaygın görülen hastalıkların teşhisinin kolaylaşması için MR görüntüleri üzerinden patolojik durumları da algılayabilen modellerin geliştirilmesi için daha ileri düzey yapay zekâ çalışmalarına ihtiyaç duyulmaktadır.

7. KAYNAKÇA

1. <Milor - Peterson's Principles of Oral and Maxillofacial Surgery-People's Medical Publishing House (2012).pdf>.
2. Leeuw Rd, Klasser GD. Orofacial pain : guidelines for assessment, diagnosis, and management. Sixth edition. ed. Hanover Park, IL: Quintessence Publishing Co, Inc.; 2018.
3. Jeffrey Okeson - Management of Temporomandibular Disorders and Occlusion-Mosby _ Elsevier (2019).pdf.
4. <Ingrid Rozylo-Kalinowska, Kaan Orhan - Imaging of the Temporomandibular Joint-Springer International Publishing (2019).pdf>.
5. Harorlı A, Akgül M, Yılmaz B, Bilge O, Dağıstan S, Çakur B, et al. Ağız, Diş ve Çene Radyolojisi. 1. baskı İstanbul; Nobel Tıp Kitapevleri Tic. Ltd Şti. 2014:484-500.
6. Butzke KW, Batista Chaves KD, Dias da Silveira HE, Dias da Silveira HL. Evaluation of the reproducibility in the interpretation of magnetic resonance images of the temporomandibular joint. Dentomaxillofac Radiol. 2010;39(3):157-61. doi: 10.1259/dmfr/16076453. PubMed PMID: 20203277; PubMed Central PMCID: PMC3520221.
7. Nebbe B, Brooks SL, Hatcher D, Hollender LG, Prasad NG, Major PW. Magnetic resonance imaging of the temporomandibular joint: interobserver agreement in subjective classification of disk status. Oral Surg Oral Med Oral Pathol Oral Radiol Endod. 2000;90(1):102-7. doi: 10.1067/moe.2000.106300. PubMed PMID: 10884644.
8. Widmalm SE, Brooks SL, Sano T, Upton LG, McKay DC. Limitation of the diagnostic value of MR images for diagnosing temporomandibular joint disorders. Dentomaxillofac Radiol. 2006;35(5):334-8. doi: 10.1259/dmfr/23427399. PubMed PMID: 16940481.
9. Li M, Jiang Y, Zhang Y, Zhu H. Medical image analysis using deep learning algorithms. Front Public Health. 2023;11:1273253. Epub 20231107. doi: 10.3389/fpubh.2023.1273253. PubMed PMID: 38026291; PubMed Central PMCID: PMC662291.
10. Suganyadevi S, Seethalakshmi V, Balasamy K. A review on deep learning in medical image analysis. International Journal of Multimedia Information Retrieval. 2022;11(1):19-38. doi: 10.1007/s13735-021-00218-1.
11. Neil S. Norton - Netter's Head and Neck Anatomy for Dentistry, Second Edition-Elsevier _ Saunders (2012).pdf.
12. DemİRsoy MS, Akbulut N. TEMPOROMANDİBULER EKLEM DİSFONKSİYONU:Redüksiyonsuz Disk Deplasmanı / Artrosentez. Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi. 2020;1-. doi: 10.17567/ataunidfd.519370.
13. Drake RL, Vogl W, Mitchell AWM, Gray H. Gray's Anatomy for Students: Churchill Livingstone/Elsevier; 2010.
14. Tuncer A. Chapter 14 - Kinesiology of the temporomandibular joint. In: Angin S, Şimşek IE, editors. Comparative Kinesiology of the Human Body: Academic Press; 2020. p. 285-302.
15. Standing S, Gray H. Gray's anatomy: the anatomical basis of clinical practice. (No Title). 2022.

16. Abdullakutty A, Sidebottom AJ. Surgical Pathways to the Temporomandibular Joint. In: Connelly ST, Tartaglia GM, Silva RG, editors. Contemporary Management of Temporomandibular Disorders: Surgical Treatment. Cham: Springer International Publishing; 2019. p. 37-56.
17. Wilkie G, Al-Ani Z. Temporomandibular joint anatomy, function and clinical relevance. *Br Dent J.* 2022;233(7):539-46. Epub 20221014. doi: 10.1038/s41415-022-5082-0. PubMed PMID: 36241801.
18. Lee Y-H, Lee K, Auh QS. MRI-Based Assessment of Masticatory Muscle Changes in TMD Patients after Whiplash Injury. *Journal of Clinical Medicine.* 2021;10:1404. doi: 10.3390/jcm10071404.
19. Gilroy AM, MacPherson BR, Wikenheiser JC. Atlas of Anatomy: Thieme; 2020.
20. McNamara JA, Jr. The independent functions of the two heads of the lateral pterygoid muscle. *Am J Anat.* 1973;138(2):197-205. doi: 10.1002/aja.1001380206. PubMed PMID: 4201159.
21. Lee Y-H. Functional Anatomy of the Temporomandibular Joint and Pathologic Changes in Temporomandibular Disease Progression: A Narrative Review. 2024;17:14-35. doi: 10.5856/JKDS.2024.17.1.14.
22. Quinn PD, Granquist E. Atlas of Temporomandibular Joint Surgery: Second Edition 2015. 1-252 p.
23. Abubaker AO, Raslan WF, Sotereanos GC. Estrogen and progesterone receptors in temporomandibular joint discs of symptomatic and asymptomatic persons: a preliminary study. *J Oral Maxillofac Surg.* 1993;51(10):1096-100. doi: 10.1016/s0278-2391(10)80448-3. PubMed PMID: 7692023.
24. Milam SB, Aufdemorte TB, Sheridan PJ, Triplett RG, Van Sickels JE, Holt GR. Sexual dimorphism in the distribution of estrogen receptors in the temporomandibular joint complex of the baboon. *Oral Surg Oral Med Oral Pathol.* 1987;64(5):527-32. doi: 10.1016/0030-4220(87)90025-9. PubMed PMID: 3478633.
25. Liu F, Steinkeler A. Epidemiology, diagnosis, and treatment of temporomandibular disorders. *Dent Clin North Am.* 2013;57(3):465-79. doi: 10.1016/j.cden.2013.04.006. PubMed PMID: 23809304.
26. Bell W. Temporomandibular disorders, ed 3, Chicago. Year Book Medical Publishers. 1990;77.
27. Griffiths RH. Report of the President's Conference on the Examination, Diagnosis, and Management of Temporomandibular Disorders. The Journal of the American Dental Association. 1983;106(1):75-7. doi: <https://doi.org/10.14219/jada.archive.1983.0020>.
28. Yun PY, Kim YK. The role of facial trauma as a possible etiologic factor in temporomandibular joint disorder. *J Oral Maxillofac Surg.* 2005;63(11):1576-83. doi: 10.1016/j.joms.2005.05.318. PubMed PMID: 16243173.
29. Yang X, Pernu H, Pyhtinen J, Tiilikainen PA, Oikarinen KS, Raustia AM. MR Abnormalities of the Lateral Pterygoid Muscle in Patients with Nonreducing Disk Displacement of the TMJ. *CRANIO®.* 2002;20(3):209-21. doi: 10.1080/08869634.2002.11746213.
30. Taskaya-Yilmaz N, Ceylan G, Incesu L, Muglali M. A possible etiology of the internal derangement of the temporomandibular joint based on the MRI observations of the lateral pterygoid muscle. *Surg Radiol Anat.* 2005;27(1):19-24. Epub 20041126. doi: 10.1007/s00276-004-0267-6. PubMed PMID: 15750717.
31. Foucart JM, Carpentier P, Pajoni D, Marguelles-Bonnet R, Pharaboz C. MR of 732 TMJs: anterior, rotational, partial and sideways disc displacements. *Eur J Radiol.* 1998;28(1):86-94. doi: 10.1016/s0720-048x(97)00102-2. PubMed PMID: 9717628.

32. Heffez L, Jordan S. A classification of temporomandibular joint disk morphology. *Oral Surg Oral Med Oral Pathol.* 1989;67(1):11-9. doi: 10.1016/0030-4220(89)90293-4. PubMed PMID: 2911439.
33. Marguelles-Bonnet RE, Carpentier P, Yung JP, Defrennes D, Pharaboz C. Clinical diagnosis compared with findings of magnetic resonance imaging in 242 patients with internal derangement of the TMJ. *J Orofac Pain.* 1995;9(3):244-53. PubMed PMID: 8995924.
34. Tasaki MM, Westesson PL, Isberg AM, Ren YF, Tallents RH. Classification and prevalence of temporomandibular joint disk displacement in patients and symptom-free volunteers. *Am J Orthod Dentofacial Orthop.* 1996;109(3):249-62. doi: 10.1016/s0889-5406(96)70148-8. PubMed PMID: 8607470.
35. Aiken A, Bouloux G, Hudgins P. MR imaging of the temporomandibular joint. *Magn Reson Imaging Clin N Am.* 2012;20(3):397-412. Epub 20120715. doi: 10.1016/j.mric.2012.05.002. PubMed PMID: 22877948.
36. Whyte AM, McNamara D, Rosenberg I, Whyte AW. Magnetic resonance imaging in the evaluation of temporomandibular joint disc displacement—a review of 144 cases. *International Journal of Oral and Maxillofacial Surgery.* 2006;35(8):696-703. doi: <https://doi.org/10.1016/j.ijom.2005.12.005>.
37. Peck CC, Goulet JP, Lobbezoo F, Schiffman EL, Alstergren P, Anderson GC, et al. Expanding the taxonomy of the diagnostic criteria for temporomandibular disorders. *J Oral Rehabil.* 2014;41(1):2-23. doi: 10.1111/joor.12132. PubMed PMID: 24443898; PubMed Central PMCID: PMC4520529.
38. Warburton G. Internal Derangements of the Temporomandibular Joint. 2021. p. 1361-80.
39. Scrivani SJ, Keith DA, Kaban LB. Temporomandibular disorders. *N Engl J Med.* 2008;359(25):2693-705. doi: 10.1056/NEJMra0802472. PubMed PMID: 19092154.
40. Mallya S, Lam E. *White and Pharoah's oral radiology: principles and interpretation*: Elsevier Health Sciences; 2018.
41. Brooks SL, Brand JW, Gibbs SJ, Hollender L, Lurie AG, Omnell KA, et al. Imaging of the temporomandibular joint: a position paper of the American Academy of Oral and Maxillofacial Radiology. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod.* 1997;83(5):609-18. doi: 10.1016/s1079-2104(97)90128-1. PubMed PMID: 9159823.
42. Robba T, Tanteri C, Tanteri G. *MRI of the Temporomandibular Joint: Correlation Between Imaging and Pathology*. Springer, 2020.
43. Baş AH, Radyolojisi B. 1. baskı. Ankara: MN Medikal/Nobel Basım Yayın. 2008:133-5.
44. Lewis EL, Dolwick MF, Abramowicz S, Reeder SL. Contemporary imaging of the temporomandibular joint. *Dent Clin North Am.* 2008;52(4):875-90, viii. doi: 10.1016/j.cden.2008.06.001. PubMed PMID: 18805233.
45. Yıldırım D, Alkış Ü. Temporomandibular Eklem Bozukluklarının Değerlendirilmesinde Kullanılan Görüntüleme Yöntemleri. *SDU Journal of Health Science Institute/SDÜ Sağlık Bilimleri Enstitüsü Dergisi.* 2016;7(2).
46. Adam Erden AC, Karakiş D. Temporomandibular eklem düzensizlikleri teşhisinde kullanılan görüntüleme yöntemleri. *Mersin Üniversitesi Sağlık Bilimleri Dergisi.* 2022;15(1):110-27. doi: 10.26559/mersinsbd.903504.
47. de Senna BR, dos Santos Silva VK, França JP, Marques LS, Pereira LJ. Imaging diagnosis of the temporomandibular joint: critical review of indications and new perspectives. *Oral Radiology.* 2009;25(2):86-98. doi: 10.1007/s11282-009-0025-x.
48. Başaran M, Bozdemir E. Güncel Literatür Işığında Temporomandibular Eklem Rahatsızlıklarında Kullanılan Görüntüleme Yöntemleri. *Haliç Üniversitesi Sağlık Bilimleri Dergisi.* 2020;3(1):15-26.

49. Schulze D, Heiland M, Thurmann H, Adam G. Radiation exposure during midfacial imaging using 4- and 16-slice computed tomography, cone beam computed tomography systems and conventional radiography. *Dentomaxillofac Radiol.* 2004;33(2):83-6. doi: 10.1259/dmfr/28403350. PubMed PMID: 15313998.
50. Walter C, Schmidt JC, Dula K, Sculean A. Cone beam computed tomography (CBCT) for diagnosis and treatment planning in periodontology: A systematic review. *Quintessence Int.* 2016;47(1):25-37.
51. Worthington P, Rubenstein J, Hatcher DC. The role of cone-beam computed tomography in the planning and placement of implants. *The Journal of the American Dental Association.* 2010;141:19S-24S.
52. Mazzi-Chaves JF, Camargo RV, Borges AF, Silva RG, Pauwels R, Silva-Sousa YTC, et al. Cone-beam computed tomography in endodontics—state of the art. *Current Oral Health Reports.* 2021;8:9-22.
53. Weiss R, Read-Fuller A. Cone beam computed tomography in oral and maxillofacial surgery: an evidence-based review. *Dentistry journal.* 2019;7(2):52.
54. Aksoy S, Orhan K. Gazi Üniversitesi Diş Hekimliği Fakültesi Dergisi. 2010;27(1):65-73.
55. Orhan K. Ultrasonography in Dentomaxillofacial Diagnostics 2021.
56. Manfredini D, Tognini F, Melchiorre D, Bazzichi L, Bosco M. Ultrasonography of the temporomandibular joint: Comparison of findings in patients with rheumatic diseases and temporomandibular disorders. A preliminary report. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology.* 2005;100(4):481-5. doi: <https://doi.org/10.1016/j.tripleo.2005.02.071>.
57. Bag AK, Gaddikeri S, Singhal A, Hardin S, Tran BD, Medina JA, et al. Imaging of the temporomandibular joint: An update. *World J Radiol.* 2014;6(8):567-82. doi: 10.4329/wjr.v6.i8.567. PubMed PMID: 25170394; PubMed Central PMCID: PMC4147437.
58. Rodrigues JA, Krois J, Schwendicke F. Demystifying artificial intelligence and deep learning in dentistry. *Braz Oral Res.* 2021;35:e094. Epub 20210813. doi: 10.1590/1807-3107bor-2021.vol35.0094. PubMed PMID: 34406309.
59. Turing AM. Computing machinery and intelligence. *Mind.* 1950;59(October):433-60.
60. Taulli T. *Artificial Intelligence Basics: A Non-Technical Introduction*: Apress; 2019.
61. McCarthy J, Minsky M, Rochester N, Shannon C. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine.* 2006;27:12-4.
62. Russell SJ, Norvig P. *Artificial intelligence: a modern approach*: Pearson; 2016.
63. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry - A systematic review. *J Dent Sci.* 2021;16(1):508-22. Epub 20200630. doi: 10.1016/j.jds.2020.06.019. PubMed PMID: 33384840; PubMed Central PMCID: PMC7770297.
64. Erickson BJ, Korfiatis P, Akkus Z, Kline TL. Machine Learning for Medical Imaging. *Radiographics.* 2017;37(2):505-15. Epub 20170217. doi: 10.1148/rg.2017160130. PubMed PMID: 28212054; PubMed Central PMCID: PMC5375621.
65. Heo MS, Kim JE, Hwang JJ, Han SS, Kim JS, Yi WJ, et al. Artificial intelligence in oral and maxillofacial radiology: what is currently possible? *Dentomaxillofac Radiol.* 2021;50(3):20200375. Epub 20201116. doi: 10.1259/dmfr.20200375. PubMed PMID: 33197209; PubMed Central PMCID: PMC7923066.
66. Nagi R, Aravinda K, Rakesh N, Gupta R, Pal A, Mann AK. Clinical applications and performance of intelligent systems in dental and maxillofacial radiology: A review.

- Imaging Sci Dent. 2020;50(2):81-92. Epub 20200618. doi: 10.5624/isd.2020.50.2.81. PubMed PMID: 32601582; PubMed Central PMCID: PMC7314602.
67. Shiruru K. AN INTRODUCTION TO ARTIFICIAL NEURAL NETWORK. International Journal of Advance Research and Innovative Ideas in Education. 2016;1:27-30.
68. Öztemel E. Yapay sinir ağıları. PapatyaYayincılık, İstanbul. 2003.
69. YILMAZ DÖÜA. Yapay zekâ: KODLAB YAYIN DAĞITIM YAZILIM LTD. ŞTİ.; 2021.
70. Yayık A, Kutlu Y. Yapay Sinir Ağları ile Kriptoloji Uygulamaları 2013.
71. Kayakuş M, Terzioğlu M. Yapay sinir ağıları ve çoklu doğrusal regresyon kullanarak emeklilik fonu net varlık değerlerinin tahmin edilmesi. Bilişim Teknolojileri Dergisi. 2021;14(1):95-103.
72. Öztürk K, Şahin ME. Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. Takvim-i Vekayi. 2018;6(2):25-36.
73. Ağyar Z. Yapay sinir ağlarının kullanım alanları ve bir uygulama. Mühendis ve Makine. 2015;56(662):22-3.
74. Erbaş Ü. Yapay Sinir ağları Ve Uygulama Alanları [Master's]. Turkey: Marmara Üniversitesi (Turkey); 2005.
75. Işık G, Artuner H, editors. Recognition of radio signals with deep learning Neural Networks. 2016 24th Signal Processing and Communication Application Conference (SIU); 2016: IEEE.
76. İşeri İ, Karakurt M. Patoloji Görüntülerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması. Avrupa Bilim ve Teknoloji Dergisi. 2022;(33):192-206. doi: 10.31590/ejosat.1011091.
77. Shrestha A, Mahmood A. Review of Deep Learning Algorithms and Architectures. IEEE Access. 2019;7:53040-65. doi: 10.1109/ACCESS.2019.2912200.
78. Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. Journal of Big Data. 2021;8(1). doi: 10.1186/s40537-021-00444-8.
79. Hubel DH, Wiesel TN. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. J Physiol. 1962;160(1):106-54. doi: 10.1113/jphysiol.1962.sp006837. PubMed PMID: 14449617; PubMed Central PMCID: PMC7314602.
80. Altan G. DeepGraphNet: Grafiklerin Sınıflandırılmasında Derin Öğrenme Modelleri. European Journal of Science and Technology. 2019:319-27. doi: 10.31590/ejosat.638256.
81. Choy G, Khalilzadeh O, Michalski M, Do S, Samir AE, Panykh OS, et al. Current Applications and Future Impact of Machine Learning in Radiology. Radiology. 2018;288(2):318-28. Epub 20180626. doi: 10.1148/radiol.2018171820. PubMed PMID: 29944078; PubMed Central PMCID: PMC6542626.
82. Mohapatra S, Swarnkar T, Das J. 2 - Deep convolutional neural network in medical image processing. In: Balas VE, Mishra BK, Kumar R, editors. Handbook of Deep Learning in Biomedical Engineering: Academic Press; 2021. p. 25-60.
83. Kim M, Yun J, Cho Y, Shin K, Jang R, Bae HJ, et al. Deep Learning in Medical Imaging. Neurospine. 2019;16(4):657-68. Epub 20191231. doi: 10.14245/ns.1938396.198. PubMed PMID: 31905454; PubMed Central PMCID: PMC6945006.
84. Ker J, Wang L, Rao J, Lim T. Deep Learning Applications in Medical Image Analysis. IEEE Access. 2017;PP:1-. doi: 10.1109/ACCESS.2017.2788044.
85. Hesamian MH, Jia W, He X, Kennedy P. Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. Journal of Digital Imaging. 2019;32(4):582-96. doi: 10.1007/s10278-019-00227-x.
86. Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. Dentomaxillofac

- Radiol. 2022;51(1):20210197. Epub 20210708. doi: 10.1259/dmfr.20210197. PubMed PMID: 34233515; PubMed Central PMCID: PMC8693331.
87. İnik Ö, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*. 2017;6(3):85-104.
88. Serbest K, Aktürk S. Nesne Tespiti İçin Derin Öğrenme Kütüphanelerinin İncelenmesi. *Journal of Smart Systems Research*. 2022;3(2):97-119.
89. LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*. 1998;86(11):2278-324.
90. Krizhevsky A, Sutskever I, Hinton GE. 2012 AlexNet. *Adv Neural Inf Process Syst*. 2012:1-9.
91. Zeiler MD, Fergus R, editors. Visualizing and Understanding Convolutional Networks. *Computer Vision – ECCV 2014*; 2014 2014//; Cham: Springer International Publishing.
92. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:14091556*. 2014.
93. Szegedy C, Wei L, Yangqing J, Sermanet P, Reed S, Anguelov D, et al., editors. Going deeper with convolutions. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2015 7-12 June 2015.
94. He K, Zhang X, Ren S, Sun J, editors. Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016 27-30 June 2016.
95. Huang G, Liu Z, Maaten LVD, Weinberger KQ, editors. Densely Connected Convolutional Networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2017 21-26 July 2017.
96. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *ArXiv*. 2015;abs/1505.04597.
97. Eker AG, Duru N. Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları. *Acta Infologica*. 2021;5(2):459-74. doi: 10.26650/acin.927561.
98. Koç A, Akgün D. U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması. *European Journal of Science and Technology*. 2021. doi: 10.31590/ejosat.959590.
99. Redmon J, Divvala S, Girshick R, Farhadi A. You Only Look Once: Unified, Real-Time Object Detection 2016. 779-88 p.
100. Hussain M. YOLOv1 to v8: Unveiling Each Variant–A Comprehensive Review of YOLO. *IEEE Access*. 2024;12:42816-33. doi: 10.1109/ACCESS.2024.3378568.
101. Özcan B, Bakour K. YAPAY ZEKA DESTEKLİ BEYİN GÖRÜNTÜLERİ ÜZERİNDE TÜMÖR TESPİTİ. *International Conference on Pioneer and Innovative Studies*. 2023;1:297-306. doi: 10.59287/icpis.847.
102. Sohan M, Sai Ram T, Rami Reddy CV, editors. A Review on YOLOv8 and Its Advancements. *Data Intelligence and Cognitive Informatics*; 2024 2024//; Singapore: Springer Nature Singapore.
103. Yang W, Wu J, Zhang J, Gao K, Du R, Wu Z, et al. Deformable convolution and coordinate attention for fast cattle detection. *Computers and Electronics in Agriculture*. 2023;211:108006. doi: <https://doi.org/10.1016/j.compag.2023.108006>.
104. Toğaçar M, Ergen B. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*. 2019;31(1):109-21.
105. Doğan F, Türkoğlu İ. Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 2019;10(2):409-45. doi: 10.24012/dumf.411130.

106. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nature Reviews Cancer*. 2018;18(8):500-10. doi: 10.1038/s41568-018-0016-5.
107. Gupta R, Srivastava D, Sahu M, Tiwari S, Ambasta RK, Kumar P. Artificial intelligence to deep learning: machine intelligence approach for drug discovery. *Molecular Diversity*. 2021;25(3):1315-60. doi: 10.1007/s11030-021-10217-3.
108. Gore JC. Artificial intelligence in medical imaging. Elsevier; 2020. p. A1-A4.
109. Zhao M, Wang D, Li J. Data management and visualization of wearable medical devices assisted by artificial intelligence. *Network Modeling Analysis in Health Informatics and Bioinformatics*. 2021;10(1):53.
110. Nguyen TT, Larrivée N, Lee A, Bilaniuk O, Durand R. Use of artificial intelligence in dentistry: current clinical trends and research advances. *J Can Dent Assoc*. 2021;87(17):1488-2159.
111. Patil S, Albogami S, Hosmani J, Mujoo S, Kamil MA, Mansour MA, et al. Artificial intelligence in the diagnosis of oral diseases: applications and pitfalls. *Diagnostics*. 2022;12(5):1029.
112. Agrawal P, Nikhade P. Artificial Intelligence in Dentistry: Past, Present, and Future. *Cureus*. 2022;14(7):e27405. Epub 20220728. doi: 10.7759/cureus.27405. PubMed PMID: 36046326; PubMed Central PMCID: PMC9418762.
113. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac Radiol*. 2020;49(1):20190107. Epub 20190814. doi: 10.1259/dmfr.20190107. PubMed PMID: 31386555; PubMed Central PMCID: PMC6957072.
114. Leite AF, Gerven AV, Willems H, Beznik T, Lahoud P, Gaêta-Araujo H, et al. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clinical oral investigations*. 2021;25:2257-67.
115. Chen Z, Liu Y, Xie X, Deng F. Influence of bone density on the accuracy of artificial intelligence-guided implant surgery: An in vitro study. *The Journal of Prosthetic Dentistry*. 2022.
116. Li S, Liu J, Zhou Z, Zhou Z, Wu X, Li Y, et al. Artificial intelligence for caries and periapical periodontitis detection. *Journal of dentistry*. 2022;122:104107.
117. Hiraiwa T, Arijji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, et al. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofacial Radiology*. 2019;48(3):20180218.
118. Yüce F, Taşşöker M. Diş hekimliğinde yapay zeka uygulamaları. *7tepe Klinik Dergisi*. 19(2):141-9.
119. Kise Y, Ikeda H, Fujii T, Fukuda M, Arijji Y, Fujita H, et al. Preliminary study on the application of deep learning system to diagnosis of Sjögren's syndrome on CT images. *Dentomaxillofac Radiol*. 2019;48(6):20190019. Epub 20190522. doi: 10.1259/dmfr.20190019. PubMed PMID: 31075042; PubMed Central PMCID: PMC6747436.
120. Arijji Y, Fukuda M, Kise Y, Nozawa M, Yanashita Y, Fujita H, et al. 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 Surg Oral Med Oral Pathol Oral Radiol*. 2019;127(5):458-63. Epub 20181015. doi: 10.1016/j.oooo.2018.10.002. PubMed PMID: 30497907.
121. Hegde S, Ajila V, Zhu W, Zeng C. Artificial intelligence in early diagnosis and prevention of oral cancer. *Asia-Pacific journal of oncology nursing*. 2022;9(12):100133.
122. Yoo J-H, Yeom H-G, Shin W, Yun JP, Lee JH, Jeong SH, et al. Deep learning based prediction of extraction difficulty for mandibular third molars. *Scientific Reports*. 2021;11(1):1954. doi: 10.1038/s41598-021-81449-4.

123. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep Learning for the Radiographic Detection of Periodontal Bone Loss. *Scientific Reports*. 2019;9(1):8495. doi: 10.1038/s41598-019-44839-3.
124. Cha JY, Yoon HI, Yeo IS, Huh KH, Han JS. Peri-Implant Bone Loss Measurement Using a Region-Based Convolutional Neural Network on Dental Periapical Radiographs. *J Clin Med*. 2021;10(5). Epub 20210302. doi: 10.3390/jcm10051009. PubMed PMID: 33801384; PubMed Central PMCID: PMCPMC7958615.
125. Vadzyuk S, Boliuk Y, Luchynskyi M, Papinko I, Vadzyuk N. PREDICTION OF THE DEVELOPMENT OF PERIODONTAL DISEASE. *Proceeding of the Shevchenko Scientific Society Medical Sciences*. 2021;65(2). doi: 10.25040/ntsh2021.02.10.
126. Bernauer SA, Zitzmann NU, Joda T. The use and performance of artificial intelligence in prosthodontics: a systematic review. *Sensors*. 2021;21(19):6628.
127. Subramanian AK, Chen Y, Almalki A, Sivamurthy G, Kafle D. Cephalometric analysis in orthodontics using artificial intelligence—A comprehensive review. *BioMed Research International*. 2022;2022(1):1880113.
128. Ryu J, Lee Y-S, Mo S-P, Lim K, Jung S-K, Kim T-W. Application of deep learning artificial intelligence technique to the classification of clinical orthodontic photos. *BMC Oral Health*. 2022;22(1):454.
129. Kök H, Acilar AM, İzgi MS. Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Progress in Orthodontics*. 2019;20:1-10.
130. Xie X, Wang L, Wang A. Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *Angle Orthod*. 2010;80(2):262-6. doi: 10.2319/111608-588.1. PubMed PMID: 19905850; PubMed Central PMCID: PMCPMC8973232.
131. Choi HI, Jung SK, Baek SH, Lim WH, Ahn SJ, Yang IH, et al. Artificial Intelligent Model With Neural Network Machine Learning for the Diagnosis of Orthognathic Surgery. *J Craniofac Surg*. 2019;30(7):1986-9. doi: 10.1097/scs.0000000000005650. PubMed PMID: 31205280.
132. Fukuda M, Inamoto K, Shibata N, Arijii Y, Yanashita Y, Kutsuna S, et al. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral radiology*. 2020;36:337-43.
133. Orhan K, Bayrakdar I, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *International endodontic journal*. 2020;53(5):680-9.
134. Boreak N. Effectiveness of artificial intelligence applications designed for endodontic diagnosis, decision-making, and prediction of prognosis: a systematic review. *J Contemp Dent Pract*. 2020;21(8):926-34.
135. Moutselos K, Berdouses E, Oulis C, Maglogiannis I. Recognizing Occlusal Caries in Dental Intraoral Images Using Deep Learning. *Annu Int Conf IEEE Eng Med Biol Soc*. 2019;2019:1617-20. doi: 10.1109/embc.2019.8856553. PubMed PMID: 31946206.
136. Bayrakdar IS, Orhan K, Akarsu S, Çelik Ö, Atasoy S, Pekince A, et al. Deep-learning approach for caries detection and segmentation on dental bitewing radiographs. *Oral Radiology*. 2022:1-12.
137. Başaran M, Çelik Ö, Bayrakdar IS, Bilgir E, Orhan K, Odabaş A, et al. Diagnostic charting of panoramic radiography using deep-learning artificial intelligence system. *Oral radiology*. 2022:1-7.
138. Vishwanathaiah S, Fageeh HN, Khanagar SB, Maganur PC. Artificial Intelligence Its Uses and Application in Pediatric Dentistry: A Review. *Biomedicines*. 2023;11(3):788. PubMed PMID: doi:10.3390/biomedicines11030788.

139. Kılıc MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, et al. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofacial Radiology*. 2021;50(6):20200172.
140. Xiong Y, Zhang H, Zhou S, Lu M, Huang J, Huang Q, et al. Simultaneous detection of dental caries and fissure sealant in intraoral photos by deep learning: a pilot study. *BMC Oral Health*. 2024;24(1):553.
141. You W, Hao A, Li S, Wang Y, Xia B. Deep learning-based dental plaque detection on primary teeth: a comparison with clinical assessments. *BMC Oral Health*. 2020;20(1):141. doi: 10.1186/s12903-020-01114-6.
142. Alimovski E, Erdemir G. Veri Artırma Tekniklerinin Derin Öğrenmeye Dayalı Yüz Tanıma Sisteminde Etkisi. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 2021;3(1):76-80. doi: 10.47769/izufbed.880581.
143. Tur AO. Derin Öğrenme Yöntemleri Kullanarak Etkin Ayırık İşaret Dili Tanıma Sistemi Geliştirme [M.C.E.]. Turkey: Ankara Üniversitesi (Turkey); 2021.
144. Deng X, Liu Q, Deng Y, Mahadevan S. An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Information Sciences*. 2016;340-341:250-61. doi: <https://doi.org/10.1016/j.ins.2016.01.033>.
145. Liang J. Confusion Matrix: Machine Learning. *POGIL Activity Clearinghouse*. 2022;3(4).
146. Padilla R, Netto SL, Silva EABd, editors. A Survey on Performance Metrics for Object-Detection Algorithms. 2020 International Conference on Systems, Signals and Image Processing (IWSSIP); 2020 1-3 July 2020.
147. Lee J-H, Han S-S, Kim Y, Lee C, Kim I. 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*. 2019;129. doi: 10.1016/j.oooo.2019.11.007.
148. Everingham M, Van Gool L, Williams CKI, Winn J, Zisserman A. The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*. 2010;88(2):303-38. doi: 10.1007/s11263-009-0275-4.
149. Henderson P, Ferrari V, editors. End-to-End Training of Object Class Detectors for Mean Average Precision. *Computer Vision – ACCV 2016; 2017 2017//*; Cham: Springer International Publishing.
150. Davis J, Goadrich M. The relationship between Precision-Recall and ROC curves. *Proceedings of the 23rd international conference on Machine learning*; Pittsburgh, Pennsylvania, USA: Association for Computing Machinery; 2006. p. 233–40.
151. List T, Jensen RH. Temporomandibular disorders: Old ideas and new concepts. *Cephalalgia*. 2017;37(7):692-704. doi: 10.1177/0333102416686302.
152. Valesan LF, Da-Cas CD, Réus JC, Denardin ACS, Garanhani RR, Bonotto D, et al. Prevalence of temporomandibular joint disorders: a systematic review and meta-analysis. *Clin Oral Investig*. 2021;25(2):441-53. Epub 20210106. doi: 10.1007/s00784-020-03710-w. PubMed PMID: 33409693.
153. Minervini G, Franco R, Marrapodi MM, Fiorillo L, Cervino G, Cicciù M. Prevalence of temporomandibular disorders in children and adolescents evaluated with Diagnostic Criteria for Temporomandibular Disorders: A systematic review with meta-analysis. *J Oral Rehabil*. 2023;50(6):522-30. Epub 20230321. doi: 10.1111/joor.13446. PubMed PMID: 36912441.
154. dos Anjos Pontual M, Freire J, Barbosa J, Frazão M, dos Anjos Pontual A, Fonseca da Silveira M. Evaluation of bone changes in the temporomandibular joint using cone beam CT. *Dentomaxillofacial Radiology*. 2012;41(1):24-9.
155. Tasaki MM, Westesson P-L. Temporomandibular joint: diagnostic accuracy with sagittal and coronal MR imaging. *Radiology*. 1993;186(3):723-9.

156. Wilkes CH. Internal derangements of the temporomandibular joint: pathological variations. *Archives of otolaryngology-head & neck surgery*. 1989;115(4):469-77.
157. Jeon KJ, Lee C, Choi YJ, Han S-S. Comparison of the Usefulness of CBCT and MRI in TMD Patients According to Clinical Symptoms and Age. *Applied Sciences*. 2020;10(10):3599. PubMed PMID: doi:10.3390/app10103599.
158. Hara GF, de Souza-Pinto GN, Brasil DM, Poluha RL, Iwaki LCV, Filho LI, et al. What is the image appearance of juvenile idiopathic arthritis in MRI, CT, and CBCT of TMJ? A systematic review. *Clinical Oral Investigations*. 2023;27(5):2321-33. doi: 10.1007/s00784-022-04828-9.
159. Alarabawy RA, El Ahwal HM, El Sergany MAES, Mehrez WW. Magnetic resonance imaging evaluation of temporo-mandibular joint disorders, criterial analysis and significance in comparison with arthroscopy. *The Egyptian Journal of Radiology and Nuclear Medicine*. 2016;47(2):467-75. doi: <https://doi.org/10.1016/j.ejnm.2016.01.002>.
160. Pupo YM, Pantoja LLQ, Veiga FF, Stechman-Neto J, Zwir LF, Farago PV, et al. Diagnostic validity of clinical protocols to assess temporomandibular disk displacement disorders: a meta-analysis. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*. 2016;122(5):572-86. doi: <https://doi.org/10.1016/j.oooo.2016.07.004>.
161. Nozawa M, Ito H, Ariji Y, Fukuda M, Igarashi C, Nishiyama M, et al. Automatic segmentation of the temporomandibular joint disc on magnetic resonance images using a deep learning technique. *Dentomaxillofacial Radiology*. 2021;51(1). doi: 10.1259/dmfr.20210185.
162. Lin B, Cheng M, Wang S, Li F, Zhou Q. Automatic detection of anteriorly displaced temporomandibular joint discs on magnetic resonance images using a deep learning algorithm. *Dentomaxillofacial Radiology*. 2021;51(3). doi: 10.1259/dmfr.20210341.
163. Li M, Punithakumar K, Major PW, Le LH, Nguyen KT, Pacheco-Pereira C, et al. Temporomandibular joint segmentation in MRI images using deep learning. *J Dent*. 2022;127:104345. Epub 20221108. doi: 10.1016/j.jdent.2022.104345. PubMed PMID: 36368120.
164. Ito S, Mine Y, Yoshimi Y, Takeda S, Tanaka A, Onishi A, et al. Automated segmentation of articular disc of the temporomandibular joint on magnetic resonance images using deep learning. *Scientific Reports*. 2022;12(1):221. doi: 10.1038/s41598-021-04354-w.
165. Yoon K, Kim J-Y, Kim S-J, Huh J-K, Kim J-W, Choi J. Multi-class segmentation of temporomandibular joint using ensemble deep learning. *Scientific Reports*. 2024;14(1):18990. doi: 10.1038/s41598-024-69814-5.
166. Lee Y-H, Won JH, Kim S, Auh QS, Noh Y-K. Advantages of deep learning with convolutional neural network in detecting disc displacement of the temporomandibular joint in magnetic resonance imaging. *Scientific Reports*. 2022;12(1):11352. doi: 10.1038/s41598-022-15231-5.
167. Li Y, Li W, Wang L, Wang X, Gao S, Liao Y, et al. Detecting anteriorly displaced temporomandibular joint discs using super-resolution magnetic resonance imaging: a multi-center study. *Frontiers in Physiology*. 2024;14. doi: 10.3389/fphys.2023.1272814.
168. Diwan T, Anirudh G, Tembhurne JV. Object detection using YOLO: challenges, architectural successors, datasets and applications. *Multimed Tools Appl*. 2023;82(6):9243-75. Epub 20220808. doi: 10.1007/s11042-022-13644-y. PubMed PMID: 35968414; PubMed Central PMCID: PMCPCMC9358372.
169. Almufareh MF, Imran M, Khan A, Humayun M, Asim M. Automated Brain Tumor Segmentation and Classification in MRI Using YOLO-Based Deep Learning. *IEEE Access*. 2024;12:16189-207. doi: 10.1109/ACCESS.2024.3359418.

170. Yaseen M, Ali M, Ali Shigri S, Hussain A, Athar A, Kim H-C. Deep Learning Based Cervical Spine Bones Detection: A Case Study Using YOLO2024. 01-5 p.
171. Alan A, Karabatak M. Veri Seti - Sınıflandırma İlişkisinde Performansa Etki Eden Faktörlerin Değerlendirilmesi. Fırat Üniversitesi Mühendislik Bilimleri Dergisi. 2020;32(2):531-40. doi: 10.35234/fumbd.738007.
172. Eşer G, Duman ŞB, Bayrakdar İŞ, Çelik Ö. Classification of temporomandibular joint osteoarthritis on cone beam computed tomography images using artificial intelligence system. Journal of oral rehabilitation. 2023;50(9):758-66.
173. Kao ZK, Chiu NT, Wu HH, Chang WC, Wang DH, Kung YY, et al. Classifying Temporomandibular Disorder with Artificial Intelligent Architecture Using Magnetic Resonance Imaging. Ann Biomed Eng. 2023;51(3):517-26. Epub 20220829. doi: 10.1007/s10439-022-03056-2. PubMed PMID: 36036857.
174. Tassoker M, Hakli H, Yaman MF, Ekmekci SN, Incekara S, Kamaci S, et al. Automatic detection of degenerative changes in the temporomandibular joint region using deep learning with panoramic radiographs. Balkan Journal of Dental Medicine. 2024;28(2):99-116.
175. Fitria M, Elma Y, Oktiana M, Saddami K, Novita R, Putri R, et al. THE DEEP LEARNING MODEL FOR DECAYED-MISSING-FILLED TEETH DETECTION: A COMPARISON BETWEEN YOLOV5 AND YOLOV8. Jordanian Journal of Computers and Information Technology. 2024;1. doi: 10.5455/jjcit.71-1710834785.
176. Bonfanti-Gris M, Herrera A, Paraíso-Medina S, Alonso-Calvo R, Martínez-Rus F, Pradíes G. Performance evaluation of three versions of a convolutional neural network for object detection and segmentation using a multiclass and reduced panoramic radiograph dataset. J Dent. 2024;144:104891. Epub 20240216. doi: 10.1016/j.jdent.2024.104891. PubMed PMID: 38367827.
177. Yoon K, Kim JY, Kim SJ, Huh JK, Kim JW, Choi J. Explainable deep learning-based clinical decision support engine for MRI-based automated diagnosis of temporomandibular joint anterior disk displacement. Comput Methods Programs Biomed. 2023;233:107465. Epub 20230305. doi: 10.1016/j.cmpb.2023.107465. PubMed PMID: 36933315.
178. Abd Elaziz M, Dahou A, Dahaba M, ElBeshlawy DM, Ewees AA, Al-Betar MA, et al. Mandibular condyle detection using deep learning and modified mountaineering team-based optimization algorithm. Alexandria Engineering Journal. 2024;107:280-97. doi: <https://doi.org/10.1016/j.aej.2024.06.096>.

8. EKLER

EK A: Etik kurul onayı

