



**YAPAY ZEKÂ SİSTEMİ KULLANILARAK KONİK IŞINLI
BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE
TEMPOROMANDİBULAR EKLEM
OSTEOARTRİTİNİN SINIFLANDIRILMASI**

GÖZDE EŞER
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

Tez Danışmanı
Doç. Dr. Şuayip Burak DUMAN

Uzmanlık Tezi-2023

T.C.
İNÖNÜ ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

**YAPAY ZEKÂ SİSTEMİ KULLANILARAK KONİK IŞINLI
BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE
TEMPOROMANDİBULAR EKLEM OSTEOARTRİTİNİN
SINIFLANDIRILMASI**

Gözde EŞER

Ağız, Diş ve Çene Radyolojisi Anabilim Dalı

Uzmanlık Tezi

Tez Danışmanı

Doç. Dr. Şuayip Burak Duman

MALATYA

2023

İÇİNDEKİLER

ÖZET	v
ABSTRACT.....	vi
SİMGELER VE KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ.....	xii
1.GİRİŞ.....	1
2. GENEL BİLGİLER	2
2.1. Temporomandibular Eklem Anatomisi ve Fonksiyonu.....	2
2.1.1. Temporomandibular Eklem Osseöz Komponentleri	3
2.1.2. Temporomandibular Eklem Yumuşak Doku Komponentleri.....	4
2.1.3. Retrodiskal Dokular	7
2.1.4. Tme'nin Arteriyel Beslenmesi.....	7
2.1.5. Tme'nin Sinir Yapısı	8
2.1.6. Mandibular Fonksiyondaki Kaslar.....	8
2.2. Temporomandibular Eklem Hastalıkları	11
2.2.1. Temporomandibular Eklem Patolojilerinin Olası Risk Faktörleri.....	11
2.2.2. Temporomandibular Bozuklukların Sınıflandırılması	11
2.3. Temporomandibular Eklem Görüntüleme Teknikleri	17
2.3.1. Panoramik Radyografi	17
2.3.2. Transkranyal Radyografi	17
2.3.3. Transfaringeal Radyografi	17
2.3.4. Transorbital Radyografi.....	18
2.3.5. Transmaksiller görüntüleme	18
2.3.6. Submentoverteks Görüntüleme.....	18
2.3.7. Bilgisayarlı Tomografi.....	18
2.3.8. Konik Işınlı Bilgisayarlı Tomografi	19

2.3.9. Ultrasonografi	19
2.3.10. Manyetik Rezonans Görüntüleme	20
2.4. Yapay Zekâ	20
2.5. Makine Öğrenmesi.....	21
2.6. Yapay Sinir Ağları (Artificial Neural Network-ANN).....	21
2.7. Yapay Sinir Ağlarının Özellikleri	23
2.8. Yapay Sinir Ağ Modelleri.....	24
2.8.1. Tek Katmanlı Algılayıcılar	24
2.8.2. Çok Katmanlı Algılayıcılar.....	24
2.8.3. İleri Beslemeli Yapay Sinir Ağları	25
2.8.4. Geri Beslemeli Yapay Sinir Ağları.....	26
2.9. Derin Öğrenme	26
2.10. Evrişimli Sinir Ağı.....	27
2.11. Evrişimli Sinir Ağı Katmanları.....	27
2.11.1.Giriş Katmanı (Input Layer)	27
2.11.2. Konvolüsyon Katmanı (Convulation Layer)	27
2.11.3. Düzleştirilmiş Doğrusal Birim Katmanı (Rectified Linear UnitsLayer(ReLu)).	28
2.11.4. Havuzlama Katmanı (Pooling Layer).....	28
2.11.5. Tam Bağlantılı Katman (Fully Connected Layer)	28
2.11.6. DropOut Katmanı	28
2.11.7. Sınıflandırma Katmanı (Classification Layer).....	28
2.12. Evrişimsel Sinir Ağının Eğitilmesi	29
2.13. Aktivasyon Fonksiyonu	30
2.14. Transfer Öğrenme	30
2.14.1. AlexNet.....	30
2.14.2. GoogleNet.....	30
2.14.3. Vgg16.....	31

2.14.4. ResNet50.....	31
2.15. Derin Öğrenme Mimarileri	32
2.15.1. Evrişimli Sinir Ağları (Convolutional Neural Network-CNN)	32
2.15.2. Tekrarlayan Sinir Ağları	35
2.15.3. Uzun Kısa Vadeli Hafıza Ağları.....	35
2.15.4. Sınırlı Boltzmann Makineleri	35
2.15.5. Derin İnanç Ağları	35
2.15.6. Derin Oto-Kodlayıcılar	35
2.16. Derin Öğrenmede Görüntü Segmentasyonu	36
2.16.1. Kodlayıcı-Kod Çözücü Modeller.....	36
2.16.2. U-Net ile Görüntü Segmentasyonu.....	36
2.17. Derin Öğrenme Kütüphaneleri.....	36
2.18. Dış Hekimliğinde Yapay Zekâ ve Kullanım Alanları	38
3.MATERYAL VE METOT	40
3.1. Hasta Seçimi	40
3.2. Radyografik Veri Setinin Elde Edilmesi	40
3.3. Görüntü Değerlendirmesi	42
3.4. Derin Öğrenme Mimarisi.....	45
3.5. Model Geliştirilmesi	45
3.6. Eğitim Aşaması.....	46
3.7. İstatiksel Analiz	49
3.7.1. Karmaşıklık Matris Hesaplama Prosedürü	49
3.8. Performans Değerlendirmesi	50
3.9. Alıcı İşlem Karakteristiği (AİK-ROC)	50
4.BULGULAR.....	52
4.1. ROC (Receiver Operating Characteristic Curve) Eğrisi Grafikleri ve AUC (Area Under Curve)	53

4.2. Precision (Kesinlik) -Recall (Duyarlılık) Eğrisi (PR Eğrisi)	55
5.TARTIŞMA	62
6.SONUÇ VE ÖNERİLER.....	76
KAYNAKLAR	77
EKLER.....	89
EK-1. Özgeçmiş.....	89
EK-2. Etik Kurul Onay Formu	90



TEŞEKKÜR

Uzmanlık eğitimim boyunca ve tez sürecinde rehberliğini ve yardımını esirgemeyen danışman hocam sayın Doç. Dr. Şuayip Burak Duman'a, teşekkürlerimi ve saygılarımı sunarım.

Uzmanlık eğitimim boyunca desteklerini esirgemeyen değerli hocalarım Doç. Dr. Oğuzhan ALTUN ve Doç. Dr. Numan Dedeoğlu'na,

Tez çalışmamızda değerli katkılarından dolayı sayın Doç. Dr. İbrahim Şevki Bayrakdar'a,

Uzmanlık eğitimim boyunca sevgilerini ve desteklerini hep hissettiğim başta Dt. Büşra Arıkan ve Dt. Duygu Çelik Özen olmak üzere asistan arkadaşlarıma ve bütün Ağız, Diş ve Çene Radyolojisi kliniği çalışanlarına,

Hayatım boyunca beni hep destekleyen, yanımda olan ve ellerinden geleni yapan anneme, babama ve kardeşime,

Hep yanımda olan eşime ve canım oğlum İbrahim Kerem EŞER'e en içten teşekkürlerimi sunarım.

ÖZET

Yapay Zekâ Sistemi Kullanılarak Konik Işınlı Bilgisayarlı Tomografi Görüntülerinde Temporomandibular Eklem Osteoartritin Sınıflandırılması

Amaç: Bu çalışmanın amacı bir yapay zekâ modeli kullanarak KIBT görüntüleri üzerinden toplumun önemli bir çoğunluğunu etkileyen temporomandibular eklem osteoartritin sınıflandırması ve temporomandibular eklem segmentasyonu yaparak, hastalığın teşhisinde hekimlere kolaylık ve zaman kazandıracak bir yöntem geliştirmektir.

Materyal ve Metot: Bu çalışmada 290 hastaya ait KIBT DICOM görüntülerinden elde edilen 2000 adet sagittal kesit (500 sağlıklı, 500 erozyon, 500 osteofit, 500 düzleşme içeren görüntü) üzerinde bir yapay zekâ modeli olan YOLOv5 mimarisinin TME segmentasyonu ve osteoartrit sınıflandırmasındaki başarıları değerlendirilmiştir. Görüntüler üzerinde temporomandibular eklem etiketlenmesi CranioCatch etiketleme yazılımı (CranioCatch, Eskişehir, Türkiye) kullanılarak yapılmıştır. Karmaşıklık matris yöntemi kullanılarak modele ait başarı metriği hesaplanmıştır.

Bulgular: Temporomandibular eklem segmentasyonu için YOLOv5 modelinin duyarlılık, kesinlik ve F1 skoru sırasıyla; 1, 0.9953, 0.9976 şeklindedir. Modelin temporomandibular eklem segmentasyonu için bulunan AUC değeri 0.9723 şeklindedir. Yine modelin temporomandibular eklem segmentasyonu için doğruluk değeri 0.9953 olarak bulunmuştur. Temporomandibular eklem osteoartrit sınıflandırması için modelin duyarlılık, kesinlik ve F1 skorları ise sırasıyla; 1, 0.7678, 0.8686 şeklindedir. Sınıflandırma için bulunan doğruluk değeri 0.7678 şeklindedir.

Sonuç: Yapılan çalışmanın temporomandibular eklem osteoartritin teşhisinde hekimlere klinik ve radyoloji rutinde kolaylık ve zaman kazandıracak bir destek mekanizması olabileceğini düşünmekteyiz. Çalışmamız ilerleyen zamanlarda yapılacak çalışmalarla daha fazla geliştirilebilir.

Anahtar kelimeler: Derin öğrenme, konik ışınli bilgisayarlı tomografi, temporomandibular eklem, temporomandibular eklem osteoartriti, yapay zeka.

ABSTRACT

Artificial Intelligence System for Classification of Temporomandibular Joint Osteoarthritis on Cone-Beam CT Images

Aim: The purpose of this study is to develop a method that will save time and convenience for physicians in the diagnosis of the disease by using an artificial intelligence model to classify temporomandibular joint osteoarthritis and segmentation of the temporomandibular joint, which affects a significant majority of the population, on CBCT images.

Material and Method: This study assessed the performance of the YOLOv5 architecture artificial intelligence model in the segmentation of the TMJ and the classification of osteoarthritis on 2000 sagittal slices (Images containing 500 healthy, 500 erosion, 500 osteophytes, 500 flattening) obtained from CBCT DICOM images of 290 patients. The temporomandibular joint was identified on the images using the labeling program CranioCatch (CranioCatch, Eskişehir, Turkey). The complexity matrix method was used to determine the model's success metric.

Results: Sensitivity, precision and F1 score of the YOLOv5 model for temporomandibular joint segmentation, respectively; 1, 0.9953, 0.9976. The model's AUC value for temporomandibular joint segmentation is 0.9723. The accuracy value for the temporomandibular joint segmentation of the model was found to be 0.9953. For the classification of temporomandibular joint osteoarthritis, the sensitivity, precision and F1 scores of the model were; 1, 0.7678, 0.8686. The accuracy value found for classification is 0.7678.

Conclusion: It is thought that the study can be a support mechanism that will save physicians time and convenience in the clinical and radiology routine in the diagnosis of temporomandibular joint osteoarthritis. Our work can be further developed with future studies.

Key words: Deep learning, cone beam computed tomography, temporomandibular joint, temporomandibular joint osteoarthritis, artificial intelligence.

SİMGELER VE KISALTMALAR DİZİNİ

%	: Yüzde
AI	: Yapay Zeka
AİK-ROC	: Alıcı İşlem Karakteristiği
ANN	: Yapay Sinir Ağları
AP	: Ortalama Kesinlik
AUC	: Area Under Curve
BT	: Bilgisayarlı Tomografi
CNN	: Evrişimli Sinir Ağı
CPH	: Cox Orantılı Tehlike Modeli
DCNN	: Derin Evrişimli Sinir Ağı
DICOM	: Digital Imaging and Communication in Medicine
DVM	: Destek Vektör Makinası
DVT	: Dental Volumetrik Tomografi
FDI	: Federation Dentaire Internationale
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
FPR	: Yanlış Pozitif Oranı
GYA	: Geriye Yayılım Algoritması
IOU	: Birleşim Üzerinden Ortalama Kesişme
JIA	: Juvenil Romatoid Artrit
JPEG	: Joint Photographic Experts Group
KIBT	: Konik Işınlı Bilgisayarlı Tomografi
Kv	: Kilovolt
mA	: Mili amper
mAP	: Ortalama Kesinlik Ölçütü

MC-DCNN	: Çok Sütunlu Derin Evrişimli Sinir Ağı
ML	: Makine Öğrenimi
MR	: Manyetik Rezonans
MRG	: Manyetik Rezonans Görüntüleme
MSU	: Mono Sodyum Ürat
PR	: Kesinlik-Duyarlılık Eğrisi
RA	: Romatoid Artrit
R-CNN	: Bölgesel Tabanlı Evrişimli Sinir Ağı
ROC	: Receiver Operating Characteristic Curve
RSF	: Rastgele Hayatta Kalma Oranı
S	: Saniye
SC-DCNN	: Tek Sütunlu Derin Evrişimli Sinir Ağı
SGİ	: Stokastik Gradyan İniş
SSD	: Tek Atış Algılama
SVA	: Shape Variation Analyzer
TME	: Temporomandibular Eklem
TMEOA	: Temporomandibular Eklem Osteoartriti
TP	: Gerçek Pozitif
TPR	: Gerçek Pozitif Oranı
USG	: Ultrasonografi
YOLO	: You Only Look Once

ŞEKİLLER DİZİNİ

Şekil No	Sayfa No
Şekil 2.1. Temporomandibular eklem	2
Şekil 2.2. Mandibular kondil	3
Şekil 2.3. Eklem diski.....	5
Şekil 2.4. Temporomandibular eklem anatomisinin yüzeysel görünümü.	9
Şekil 2.5. Temporomandibular eklem anatomisinin derin görünümü.	10
Şekil 2.6. TME'nin oblik sagittal KIBT görüntüsü	19
Şekil 2.7. Yapay zekâyı oluşturan temel kavramlar	21
Şekil 2.8. Biyolojik sinir hücresi ve yapay sinir ağı	22
Şekil 2.9. Yapay sinir hücresi	23
Şekil 2.10. Tek katmanlı algılayıcı modeli	24
Şekil 2.11. Çok katmanlı algılayıcı modeli	25
Şekil 2.12. İleri beslemeli yapay sinir ağı modeli	25
Şekil 2.13. Geri beslemeli yapay sinir ağı modeli	26
Şekil 2.14. Evrimsel sinir ağının genel mimarisi	27
Şekil 2.15. AlexNet derin öğrenme algoritması	30
Şekil 2.16. GoogleNet derin öğrenme algoritması	31
Şekil 2.17. Vgg16 ve Vgg19 derin öğrenme mimarisi görünümü	31
Şekil 2.18. ResNet bağlantı örneği	32
Şekil 2.19. YOLOv5 mimarisi	34
Şekil 3.1. Görüntülerin elde edildiği KIBT cihazı.....	41
Şekil 3.2. Temporomandibular eklemin poligonal tarzda etiketlenmesi	42
Şekil 3.3. Tip N; Normal, tipik morfoloji gösteren kondilin kortikal yüzeyinde proliferasyon veya kalınlaşma yok	43
Şekil 3.4. Tip F; Düzleşme, kondilin ön-arka ve arka-ön yüzeylerinde düzleşmiş kontur.....	44
Şekil 3.5. Tip E; Erozyon, kondilin kortikal yüzeyinde pürüzlü veya pürüzlü olmayan proliferasyon veya kısmi hipodens değişiklik	44
Şekil 3.6. Tip D; Deformite, marjinal proliferasyon ve osteofit, kondil yüzeyinde proliferasyon veya kısmi hipodens değişiklik olmaksızın, gaga şeklinde deforme olmuş bir kontura sahip kondil.....	45

Şekil.3.7. YOLOv5 modelinin temporomandibular eklem segmentasyonu için oluşturduğu tahmini görüntü	46
Şekil 3.8. YOLOv5 modelinin temporomandibular eklem osteoartritinin sınıflandırılması için oluşturduğu tahmini görüntülerden sağlıklı temporomandibular eklem.	47
Şekil 3.9. YOLOv5 modelinin temporomandibular eklem osteoartritinin sınıflandırılması için oluşturduğu tahmini görüntülerden düzleşmiş temporomandibular eklem.	48
Şekil 3.10. YOLOv5 modelinin temporomandibular eklem osteoartritinin sınıflandırılması için oluşturduğu tahmini görüntülerden osteofitin olduğu temporomandibular eklem.	48
Şekil 3.11. YOLOv5 modelinin temporomandibular eklem osteoartritinin sınıflandırılması için oluşturduğu tahmini görüntülerden erozyonun olduğu temporomandibular eklem.	49
Şekil 4.1. Temporomandibular eklem segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği.....	52
Şekil 4.2. Temporomandibular eklem osteoartrit sınıflandırması için YOLOv5 modelinin karmaşıklık matris grafiği	53
Şekil 4.3. YOLOv5 modelinin temporomandibular eklem segmentasyonu için ROC eğrisi ve AUC değeri.	54
Şekil 4.4. YOLOv5 modelinin temporomandibular eklem osteoartrit sınıflandırılması için ROC eğrisi ve AUC değeri.	55
Şekil 4.5. Temporomandibular eklem segmentasyonu için PR Eğrisi.	56
Şekil 4.6. Temporomandibular eklem osteoartrit sınıflandırması için PR Eğrisi.....	56
Şekil 4.7. Temporomandibular eklem segmentasyonu için yaptığımız çalışma sonuçlarının grafiksel gösterimi	58
Şekil 4.8. Temporomandibular eklem osteoartrit sınıflandırması için yaptığımız çalışma sonuçlarının grafiksel gösterimi	58
Şekil 4.9. Temporomandibular eklemin YOLOv5 modeli ile segmentasyonunda elde edilen F1- güven eğrisi.	59
Şekil 4.10. Temporomandibular eklemin YOLOv5 modeli ile segmentasyonunda elde edilen kesinlik-güven eğrisi.	59
Şekil 4.11. Temporomandibular eklemin YOLOv5 modeli ile segmentasyonunda elde edilen duyarlılık-güven eğrisi.	60

Şekil 4.12. Temporomandibular eklemin YOLOv5 modeli ile osteoartrit sınıflamasında elde edilen F1- güven eğrisi.....	60
Şekil 4.13. Temporomandibular eklemin YOLOv5 modeli ile osteoartrit sınıflamasında elde edilen kesinlik- güven eğrisi	61
Şekil 4.14. Temporomandibular eklemin YOLOv5 modeli ile osteoartrit sınıflamasında elde edilen kesinlik- güven eğrisi	61



TABLÖLAR DİZİNİ

Tablo No	Sayfa No
Tablo 2.1. Temporomandibular eklem hastalıklarının sınıflandırılması	12
Tablo 2.2. Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları	22
Tablo 2.3. Derin Öğrenme Kütüphaneleri	37



1.GİRİŞ

Teknoloji alanındaki gelişmeler tıp ve diş hekimliğinde büyük değişimlere neden olmuştur. Bu değişime neden olan en önemli faktörlerden biri de yapay zekâdır. Yapay zekânın özellikle hekime sağladığı kolaylıklar ve sağlık hizmetlerine katkıları sayesinde giderek daha fazla kullanılacağı düşünülmektedir. Hesaplama gücü, işlem hızındaki artış, farklı görevleri yerine getirme yeteneği, gelişmiş grafik işlem birimleri ve depolama gücü özellikle radyolojide yeni bir başlangıç kabul edilmektedir. Diş hekimliğinin de dâhil olduğu bu yeni dönem, hastalıkların önlenmesinde ve erken teşhisinde önemli bir rol oynayacaktır (1)

Diş hekimliğinde teşhis ve veri depolanmasında oral radyoloji önemli bir yer tutmaktadır. Bu alanlarda önemli kolaylıklar sağlayan yapay zekâ hakkında özellikle oral radyologların fikir sahibi olması önem arz etmektedir. Yapay zekâdan elde edeceğimiz bilgiler teşhis ve tanıya daha hızlı ve yanlışsız ulaşmamızı sağlayacaktır (2)

Diş hekimliğinde radyoloji alanında görüntüleme yöntemleri üzerinde yapay zekâ kullanımı giderek artmaktadır. Özellikle tanısal performansı ve kullanımının artmasıyla konik ışınlı bilgisayarlı tomografi (KIBT) görüntüleri üzerinde yapay zeka çalışmaları da yaygınlaşmıştır.


Bu çalışmanın da amacı yapay zekâ ile KIBT sagittal görüntüleri üzerinden toplumun büyük çoğunluğunu etkileyen bir rahatsızlık olan temporomandibular eklem osteoartritinin sınıflandırması ve temporomandibular eklem segmentasyonu yapmaktır. Yapay zekânın temporomandibular eklem osteoartritini erken teşhisi ile hastalığın prognozunda olumlu gelişmeler olacağını umut ediyoruz.

2. GENEL BİLGİLER

2.1. Temporomandibular Eklem Anatomisi ve Fonksiyonu

Baş iskeletini oluşturan eklemler arasında hareketli olan tek eklem temporomandibular eklem (TME), temporal kemiğin mandibular fossası ile mandibular kondilin kaput mandibulası arasında yer almaktadır. Mandibulanın bir eksen etrafında menteşe hareketi yapmasını sağladığından ‘ginglimoid eklem’, kayma hareketi sağladığından ‘artroidal eklem’ ve eklem boşluğu sinoviyal sıvı ile dolu olduğundan sinoviyal bir eklemdir. Temporomandibular eklem temporal kemiğin glenoid fossasına mandibular kondilin yerleşmesiyle oluşur. Bu iki kemiğin direkt artikülasyonda olmasını artiküler disk engeller. Temporomandibular eklem aynı zamanda kompaund bir eklem olarak da sınıflandırılır. Kompaund eklem için en az üç kemik varlığı gerekse de artiküler disk kompleks eklem hareketine izin veren non-ossifiye bir kemik olarak fonksiyon görür (Şekil 2.1) (3).

Bu eklemi farklılaştıran ve benzersiz kılan özelliği ise eklem yüzeyinin hiyalin kıkırdak yerine fibrokartilajla kaplı olmasıdır. Hareket sadece kemiklerin, kasların ve bağların şekliyle değil, aynı zamanda dişlerin oklüzyonuyla da yönlendirilir, çünkü her iki eklem tek bir mandibula kemiği ile birleştirilir ve birbirinden bağımsız hareket edemez (4).



Şekil 2.1. Temporomandibular eklem (5)

2.1.1.Temporomandibular Eklemnin Osseöz Komponentleri

- Mandibular kondil,
- Temporal kemik.

2.1.2.Temporomandibular Eklemnin Yumuşak Doku Komponentleri

- Artiküler disk,
- Ligamentler
- Eklem kapsülü (3).

2.1.1. Temporomandibular Eklemnin Osseöz Komponentleri

2.1.1.1. Mandibular Kondil

Mandibula U şekilli bir kemiktir. Alt dişleri destekler ve alt yüz iskeletini oluşturur. Kafa kaidesiyle kemiksel bağlantısı yoktur. Kafa iskeletine kaslar, ligamentler ve eklemlerle bağlıdır. Ramus ve korpus olmak üzere 2 parçadan oluşur. Kondil mandibulanın kafa ile eklem yaptığı bölgedir. Anteriordan bakıldığında medial ve lateral kutupları mevcuttur. Medial kutup lateral kutuptan daha belirgindir. Kondilin toplam mediolateral uzunluğu 15-20 mm'dir. Antero-posterior genişliği ise 8-10 mm'dir. Posterior eklem yüzeyi anterior eklem yüzeyinden daha geniştir. Kondilin eklem yüzeyi antero-posterior konveks ve sadece hafifçe mediolateral konvekstir (Şekil 2.2) (6).



Şekil 2.2. Mandibular kondil (5)

2.1.1.2. Temporal Kemik

Mandibular kondil, kranium ile temporal kemiğin squamoz parçasıyla eklem yapar. Temporal kemiğin bu parçası konkav mandibular fossadan oluşur. Buraya kondil yerleşir. Aynı zamanda artiküler veya glenoid fossa da denir. Mandibular fossanın anteriorunda konveks kemik uzantısı olan artiküler eminens vardır. Artiküler fossanın konveksite derecesi değişkendir fakat önemlidir. Çünkü bu yüzey mandibula anteriora pozisyonlandığında kondilin gidiş yolunu belirler. Mandibular fossanın posterior tavanı incedir. Temporal kemiğin bu kısmı ağır kuvvetler için uygun değildir. Artiküler eminens bu kuvvetleri karşılayabilecek yoğunlukta kemik içerir (6).


2.1.2. Temporomandibular Eklem Yumuşak Doku Komponentleri

2.1.2.1. Artiküler Disk

Ağız kapalı durumda iken temporomandibular eklem kondilinin apeksi üzerine oturan yoğun fibröz dokudan oluşan, bikonkav şekilli, kan damarı ve sinir lifi içermeyen eklem diski bulunur. Eklem diski sagittalden bakıldığında üç kısma ayrılabilir;

1. Anterior parçası (Pars menisküs): Öndeki ince kısım olup, lateral pterigoid kasın süperior liflerine ve kapsüle yapışır.
2. Santral parçası (Intermediate zon, pars grasilis): En ince olan bölümdür.
3. Posterior parçası (pars posterior): İyi vaskülarize ve innerve olan retrodiskal alana (bilaminer zone) yapışan en kalın bölümdür (7).

Şekil 2.3'te eklem diski ve diğer yapılar gösterilmektedir.



Şekil 2.3. Eklem diski (1.Kondil başı, 2.Pterigoid fovea, 3.Eklem Diski, 4.Eklem kapsülü, 5.Retrodiskal doku, 6.Alt eklem boşluğu, 7.Üst eklem boşluğu, 8. Artiküler eminens, 9.Zigomatik ark, 10.Dış kulak yolu, 11.Superior lateral pterigoid, 12.İnferior lateral pterigoid kas) (8)

2.1.2.2. Ligamentler

Her eklemden olduğu gibi ligamentler yapıları korumada en önemli rolü oynar. Eklem ligamentleri esnemeyen kollojen konnektif dokudan yapılmıştır. Bunlar eklem fonksiyonlarına aktif olarak katılmaz fakat sınır hareketlerini sınırlandırarak fonksiyon görür. 3 fonksiyonel ligament TME'yi destekler:

- 1- Kollateral ligamentler,
- 2- Kapsüler ligamentler,
- 3- Temporomandibular ligament.

Aynı zamanda 2 tane aksesuar ligament vardır:

- 1- Sphenomandibular ligament,
- 2- Stylomandibular ligament (6).

Kollateral Ligament

Rotasyon sırasında diskin kondille beraber hareket etmesini sağlayan diskin medial ve lateral parçalarını kondil ucuna bağlayan, kollojen konnektif dokudan oluşmuş gerçek ligamentlerdir. Diskal ligament olarak da isimlendirilir, medial ve lateral diskal ligament olmak üzere iki tanedir. Diskal ligamentlerin atışmanları, diskin, kondilin artiküler yüzeyleri üzerinde anterior ve posterior olarak rotasyon hareketi

yapmasına izin verir. Bu nedenle, bu ligamentler TME'nin menteşe hareketlerinden sorumludur (6, 8).

Kapsüler Ligament

Temporomandibular eklemi tüm yönlerden sarıp, yukarıda temporal kemiğin eklem yüzüne tutunan aşağıda kondilin boynuna tutunan liflerden oluşmaktadır. Bu sayede sinoviyal sıvının devamlılığını sağlayıp onun için bir kese görevi görür. Kapsüler ligament, ayırıcı ve yerinden çıkarıcı medial, lateral ve inferior kuvvetleri sınırlar. Kapsüler ligament iyi innerve olur ve eklem pozisyon hareketleriyle ilgili proprioseptif bilgi sağlar (6, 8).

Temporomandibular Ligament

Temporomandibular eklem lateralinde bulunmakla beraber dışta oblik içte horizontal iki kısımdan oluşur. Diğer ismi 'lateral ligament'tir. Dış oblik kısım, artiküler tüberkülün dış yüzeyinden ve zigomatik proçesten postero-inferior olarak kondil boynunun dış yüzeyine uzanır. İç horizontal kısım, artiküler tüberkülün ve zigomatik proçesin dış yüzeyinden posterior ve horizontal olarak kondilin lateral kutbuna ve artiküler diskin posterior kısmına uzanır. Horizontal parçası kondil ve diskin posteriora hareketine engel olarak, retrodiskal dokuları korur. Temporomandibular ligamentin oblik kısmı ise kondilin aşırı hareketini sınırlar, böylelikle ağzın açılma derecesini sınırlar. Ligamentin bu kısmı aynı zamanda, mandibulanın normal açılma hareketine de etki eder (6, 8).

Aksesuar Ligamentler

Sphenomandibular Ligament

Bu ligament, sfenoid ve petrotimpanik fissürün açısal omurgasından kaynaklanır ve daha sonra mandibula lingulasına girmek için aşağı ve dışa doğru ilerler. Ligament lateral olarak lateral pterygoid kasla ilişkilidir, aurikülotemporal sinir arkada, maksiller arter önde, alt alveolar sinir ve damarlar altta ve mandibular foramenlere ve parotis bezinin bir lobülüne girer ve son olarak medial olarak korda timpani siniri ile medial pterygoid ve yağ ile farenks duvarı ve faringeal damarlar araya girer. Ligament,

miyelohyoid sinir ve damarlar tarafından delinir. Bu bağ, çene hareketleri sırasında pasiftir ve ağzın hem açılması hem de kapanması sırasında nispeten aynı derecede gerilimi korur (4).

Stylomandibular Ligament

İkinci aksesuar ligamenttir. Bu ligament, styloid proçesten başlar, aşağıya ve ileriye ramusun arka sınırına ve köşesine uzanır. Mandibula protrüzyondayken iyice gerilir fakat mandibula açıldığında iyice gevşemiş durumdadır. Bu ligament bu nedenle protrüziv hareketleri sınırlar (6).

Eklem Kapsülü

Fibröz kapsül, eklemi tamamen çevreleyen ince bir doku kılıfıdır. Kranial eklem yüzeyinin çevresinden mandibula boynuna kadar uzanır. Kapsülün iç yüzeyi sinoviyal membran ile kaplıdır. Kapsülün görevleri ise diskin metabolik ihtiyaçlarını karşılayan sinoviyal sıvının üretimi, mandibular hareketlerin kısıtlanması ve proprioseptif özellik göstermesidir (3, 4).

2.1.3. Retrodiskal Dokular

Retrodiskal dokular süperior ve inferior lamellerden oluşan, bilaminar bölge olarak da isimlendirilen, gevşek damarlı doku bölgesini sınırlayan dokulardır. Retrodiskal dokular sinirden zengindir. Süperior lamina mandibular fossanın posterior iç duvarına yerleşir ve elastinden zengindir. Çene açılırken gerilerek kondil translasyonu ve diskin öne hareketini sağlar. Çene kapanırken ise diskin posteriora çekilmesini sağlar. Inferior lamina ise kondilin posterior yüzeyine tutunur. Retrodiskal dokular özellikle anterior disk deplasmanı vakalarında ağrıya neden olabilir (9).

2.1.4. Tme'nin Arteriyel Beslenmesi

Temporomandibular eklemi besleyen ana arterler arteria maksillaris, arteria temporalis superficialis, masseterik arterdir. Arteria alveolaris inferior ve kondil çevresindeki arter ağı da kanlanmada rol alırlar. Venöz boşaltımın gerçekleştiği venler ise vena temporalis superficialis, pterigoid pleksus ve maksiller pleksustur (10).

2.1.5. Tme'nin Sinir Yapısı

TME'nin, motor ve sensitif inervasyonunu, aurikulotemporal sinirin dallarından gelen massater ve derin posterior temporal sinir sağlamaktadır (10).

2.1.6. Mandibular Fonksiyondaki Kaslar


Mandibula fonksiyonel hareketlerini 4 çift çiğneme kası sağlamaktadır.

Massater Kası

Yüzeyel ve derin olmak üzere iki parçadan oluşan kasın lifleri zigomatik arkten başlar, mandibular ramusun alt sınırına doğru ikinci molar bölgede sonlanır. Kasın yüzeysel parçasının lifleri geriye ve aşağıya doğru uzanırken, derin parçanın lifleri daha dikey olarak uzanır. Çenenin kapatılmasını yani mandibular elevasyonu sağlamakla beraber yüzeyel parça mandibulanın öne hareketini destekler (11).

Temporalis Kası

Liflerin yönlerine ve fonksiyonlarına göre ön, orta ve arka olmak üzere üç parçaya ayrılan temporalis kası, kafatasının lateral yüzeyinden ve temporal fossadan başlayan lifleri birlikte zigomatik arkten geçerek mandibulanın koronoid çıkıntısına yapışır. Ön parçanın lifleri dikey, orta parçanın lifleri öne doğru oblik, arka parçanın lifleri ise yatay öne ve aşağı doğru uzanır. Temel görevi mandibulanın elevasyonu olmakla birlikte mandibulanın retrüzyonunda yani arkaya hareketinden de fonksiyon gösterdiği düşünülmektedir (Şekil 2.4) (11).



Şekil 2.4. Temporomandibular eklem anatomisinin yüzeysel görünümü. (a) temporalis kası, (b) temporomandibular ligament, (c) lateral pterygoid kas ve (d) masseter kası (12)

Medial Pterygoid Kas

Pterygoid fossadan başlayıp mandibular açının medial yüzeyi boyunca aşağı, geriye ve dışa doğru uzanan medial pterygoid kas masseter kas ile birlikte mandibulayı destekler. Medial pterygoid kas kasıldığında mandibula yükselip dişler temasa gelir. Ayrıca mandibulanın protrusiv hareketlerinde de fonksiyon görür (13).

Lateral Pterygoid Kas

Yapılan son çalışmalarla lateral pterygoid kasın birbirinden tamamen farklı işlevleri olan iki kısımdan oluştuğu belirtilmiştir.

Bu kaslar;

1. Inferior lateral pterygoid ve
2. Superior lateral pterygoid olarak tanımlanmaktadır.

Inferior Lateral Pterygoid Kas


Lateral pterygoid plakanın dış yüzeyinden başlar ve kondil boynunda sonlanır. Bu kas geriye, yukarı ve dışa doğru uzanır. Bu kas çift taraflı olarak eş zamanlı

kasıldığında mandibula protrüzyon yapar. Bu kas tek taraflı kasıldığında ise, mandibula kasılmanın olduğu tarafın karşı tarafına doğru lateral hareket yapar. Bu kas, mandibular depresörlerle birlikte çalıştığında ise mandibula aşağı doğru hareket eder (13).

Superior Lateral Pterygoid Kas

Sfenoid kemiğin büyük kanadının infratemporal yüzünden başlayıp yatay olarak dışa ve geriye doğru uzanarak eklem kapsülüne, kondile ve artiküler diske tutunmaktadır. Disk bu kas kasıldığı zaman anteromediale doğru çekilmektedir. Çenenin açılması sırasında işlev görmemektedir. Ancak yükseltici kaslar çalışırken fonksiyon görmektedir. Bu kas, ağız kapatılırken, laterotrüzyonda ve retrüzyonda fonksiyon görmektedir, bu hareketler sırasında kondil-disk kompleksini sürekli olarak eminensin eğimine karşı tutmaya çalışmaktadır (10).

Lateral ve medial pterygoid kaslar şekil 2.5'te gösterilmiştir.



Şekil 2.5. Temporomandibular eklem anatomisinin derin görünümü. (a) temporal kası, (b) temporal kemik, (c) mandibular kondil, (d) lateral pterygoid kas, (e) medial pterygoid kas ve (f) intraartiküler disk (12)

2.2. Temporomandibular Eklem Hastalıkları

Temporomandibular eklemde ağrı ve disfonksiyon ilk kez Cooper tarafından 1930’larda tanımlanmıştır (14). Daha sonra 1934 yılında Costen, ağrı, tinnitus, vertigo ve okspital baş ağrıları ile tanımlanan Costen sendromunu tarif etmiştir (15). Temporomandibular eklemdeki rahatsızlığın çiğneme kaslarındaki spazma bağlı olduğu düşünülerek TME ağrı disfonksiyon sendromu ve daha sonrada myofasial ağrı disfonksiyon tanımlamaları yapılmıştır. Anlaşılacağı üzere TME ‘de etiyolojileri farklı ancak benzer belirti gösteren hastalılar için farklı tanımlamalar kullanılmıştır. Temporomandibular eklem hastalıklarının 20-40 yaşları arasındaki bayanları daha çok etkilediği bildirilmektedir (14).

2.2.1. Temporomandibular Eklem Patolojilerinin Olası Risk Faktörleri

Olası risk faktörleri: yaş, cinsiyet, kişilik, okluzal sorunlar, parafonksiyonel alışkanlıklar, travma, hipermobilité, stres, sistemik faktörler ve kalıttır. Bu faktörler sınıflandırılrsa:

- 1- Predispozan faktörler: Yapısal, metabolik ve/veya psikolojik durumlar,
- 2- Başlatan faktörler: Örneğin çiğneme sistemine travma veya tekrarlayan ters yükleme,
- 3- Şiddetlendirici faktörler: Parafonksiyon, hormonal veya psikososyal faktörler olarak sınıflandırılabilir (14).

Hastalığın tanısı çoğu zaman anamnez, fizik muayene, çeşitli radyolojik tetkikler ile konulur. Hastayı hekime getiren nedenler genellikle ağrı, eklemlerde ses ve hareket kısıtlanmasıdır (14)

2.2.2. Temporomandibular Bozuklukların Sınıflandırılması (14)

Temporomandibular eklem hastalıklarının sınıflandırılması tablo 2.1’de gösterilmektedir.

Tablo 2.1. Temporomandibular eklem hastalıklarının sınıflandırılması (14)

1-Çiğneme Kaslarına Ait Rahatsızlıklar	2-TME Rahatsızlıkları	3-Kronik Mandibular Hipomobilité	4-Gelişim Bozuklukları
Koruyucu kas kontraksiyonu	A-Kondil-Disk Kompleksinde Düzensizlik	A-Ankiloz	A-Konjenital ve Gelişimsel Kemik Rahatsızlıkları
Lokal kas ağrısı	a.Disk deplasmanı	a.Fibröz	a.Agenezi
Miyofasial ağrı	b.Redüksiyonlu disk dislokasyonu	b.Kemiksel	b.Hipoplazi
Miyospazm	c.Redüksiyonsuz disk dislokasyonu	B-Kas kontraktürleri	c.Hiperplazi
Miyozit ve diğerleri	B-Eklem yüzeylerinin yapısal uyumsuzluğu	a. Miyostatik	d. Neoplazi
	a. Şekil değişiklikleri	b. Miyofibrotik	B-Konjenital ve Gelişimsel Kas Rahatsızlıkları
	b. Adezyonlar	C-Koronoid Empedans	a.Hipotrofi
	C-TME'nin İnflamatuar Hastalıkları		b.Hipertrofi
	a-Sinovit/kapsülit		c. Neoplazi
	b-Retrodiskit		
	c-Artritler (Osteoartrit/Poliartrit)		

2.2.2.1. Çiğneme Kaslarına Ait Rahatsızlıklar

Koruyucu Kas Kontraksiyonu

Bir tehdit ve yaralanma anında tehdit altındaki parçayı daha fazla yaralanmadan korumak için kastaki dizilim değişikliğidir. Patoloji kabul edilmez ve koruyucu bir mekanizma olduğu düşünülür. Ama bu durumun uzun sürmesi halinde kaslarda semptomlarla beraber lokal kas problemlerine neden olabilir (14).

Lokal Kas Ağrısı

Kasın aşırı kullanımı veya kasa gelen lokal bir travma sonrası oluşabilecek inflamatuvar olmayan, miyojenik bir ağrı bozukluğudur. Genel olarak kasın uzamış kasılmasına ilk yanıttır. Lokal kas ağrısında gerçek bir kas zayıflığı vardır ancak kas ağrısı çözüldüğünde kas gücü normale döner. Eğer çiğneme sistemindeki elevatör kaslar tutulursa ağız açmada kısıtlanma meydana gelebilir (14).

Myofasial Ağrı Sendromu (Miyofasial Triger Pointalji)

Myofasial tetik noktaları sebebiyle oluşan duysal motor ve otonomik semptomları olan bir sendromdur. Myofasial tetik noktaları ise kastaki band ya da fasya içindeki kompresyonla ağrılı olan yansıyan ağrı, motor disfonksiyon ve otonomik fenomene yol açabilen hiperirritabl odaklardır (16). Bu noktalar aktif ya da pasif olabilir. Aktif formunda sürekli bir ağrı vardır, pasif formunda ise sürekli ağrı görülmez ve sağlıklı kişilerde bulunabilir. Buna karşın aktif tetik noktaları sadece myofasial ağrı sendromlu kişilerde bulunur. Tetik noktaları kadınlarda ve en çok 31-50 yaşları arasında görülür (17).

Miyospazm

Etiyolojisi belli olmayan merkezi sinir sisteminin sebep olduğu tonik kas kasılmasıdır. Lokal elektrolit dengesindeki değişikliğin ve kas yorgunluğunun miyospazmı artırdığı düşünülmektedir (14).

Miyozit

Travma, uzamış miyospazm ya da yayılan enfeksiyon sonucu oluşabilecek kas ve tendonların lokal enfeksiyonudur. Kaslarda palpasyonda hassasiyet, gerginlik ile beraber istirahatte olan ağrı fonksiyonda artar (14).

2.2.2.2. TME Rahatsızlıkları

Kondil-Disk Kompleksi Düzensizlikleri

Kondil disk kompleksi düzensizliklerinden en çok karşılaşılan durumu olan disk yer değiştirmesi; diskin kondil başı ve temporal kemiğin eklem fossası ile normal fonksiyonel ilişkisinden çıktığı bir durumdur (14, 18).

Disk Deplasmanı

Disk deplasmanı durumunda dinlenme sırasında kondil diskin posterior bölümü ile daha çok ilişkidedir ve ağız açma sırasında kondil disk üzerinde anormal bir kayma yolu takip eder. Bu anormal kondil disk hareketi sırasında klik sesi duyulabilir (19).

Redüksiyonlu Anterior Disk Deplasmanı

Tüm sagittal görüntülerde ağız kapalı konumda diskin posterior bandı kondil başının anteriorunda yer almaktadır. Ağız açık pozisyonda ise kondil disk ilişkisi normaldir ve disk kondili yakalar. Ağız kapalıyken diskin anteriorda olmasına disk

deplasmanı, hareket sırasında kondil ve diskin tekrar uygun konuma gelmesine redüksiyonlu disk deplasmanı denir (19).

Redüksiyonsuz Anterior Disk Deplasmanı

Tüm sagittal görüntülerde ağız hem açık hem kapalı konumda iken diskin posterior bandı kondilin üst yüzeyinin önünde yer alır. Ağız açma sırasında diskin normal pozisyonuna dönememesi durumuna redüksiyonsuz disk deplasmanı denir. Çoğunlukla redüksiyonlu disk deplasmanının ilerlemesiyle oluşur. Türk popülasyonunda en çok redüksiyonsuz anterior disk deplasmanı görülmüştür, en nadir olarak ise medial ve lateral disk deplasmanı görülmüştür (19).

Artiküler Yüzeyin Yapısal Yetersizliği

Eklem yüzeyine gelen makro ve mikro travmalar sonucunda oluşan şekil değişiklikleri, adezyonlar, sublüksasyon, spontan dislokasyonu örnek olarak verilebilir (14).

TME'nin inflamatuvar hastalıkları

Artralji

Travma, enfeksiyon ya da irritasyon kaynaklı temporomandibular eklem kapsüller veya sinoviyal tabakasında görülen ağrı ve hassasiyettir. Sinoviyal tabakanın iltihabına sinovit denir. Sinovitte eklemde yukarı ya da geriye doğru yüklenilmesinde şiddetlenen lokalize bir ağrı vardır. Temporomandibular eklem bölgesinde ödem varsa şişlik görülebilir. Ligamentin gerilmesine bağlı kapsülde görülen enfeksiyona ise kapsülit denir. Eklem distraksiyonunda hastada ağrı görülür. Sinovit ve kapsülit ayırımını yapmak çok zordur (8).

Osteoartrit

Osteoartrit mekanik, genetik ve biyokimyasal faktörlerin etkisi ile özellikle yük taşıyan eklemlerde progresif kıkırdak yıkımı, subkondral skleroz, osteofit oluşumu, eklem kapsülü ve sinoviyal membranda morfolojik ve biyokimyasal değişikliklerle karakterize dejeneratif bir hastalıktır (20). Osteoartrit kronik bir hastalıktır ve ağrı, fonksiyon kaybı, güçsüzlükle karakterizedir (21).

Osteoartrit dejeneratif eklem hastalığının eş anlamlısıdır. Eklem kemik bileşenlerinin bozunmasına, eklem kemik yapılarını saran fibrokartilaj eklem dokusunun yıkımına sebep olur. Eklem adaptasyon kapasitesinin gelen aşırı kuvvetler

sonucunda aşılmasına bağlı olarak oluştuğu düşünülmektedir. Hastalık her yaşta görülebilir ancak yaşla birlikte insidansı artar ve kadınlarda daha çok görülür. Temporomandibular ekleminde ise en çok dejeneratif artrit görülür. Osteoartrit eklem kıkırdığında marjinal ve santral kemik oluşumuna, patolojik lokalize kayıplara neden olur. Hastalık asemptomatik olabileceği gibi fonksiyonla artan temporomandibular eklem ağrısı, gerginlik, ağız açmada kısıtlanma görülebilir. Hastalığın semptomları yavaş yavaş ya da aniden ortaya çıkabilir. Yine hastalık kendiliğinden geçebilir ya da tekrarlayan döngüler halinde devam edip ilerleyebilir (14).

Eklemde osteoartrit teşhisi çoğunlukla radyografi ile konulur. Radyografide eklemde düzleşme, osteofit ya da erozyon gibi yüzey düzensizlikleri gözlemlenebilir. Kondil başındaki remodeling, lokalize, yüzeysel yada kondil başının tamamında izlenebilir. Asemptomatik bireylerde kondil başında bir miktar düzleşme olabileceği gibi erozyon ya da osteofit de izlenebilir. Temporomandibular eklemde radyografide osteoartrite bağlı kemik değişikliklerinin izlenebilmesi için altı ay kadar bir sürenin geçmesi gerekebilir. Bu sebeple radyografik bulgular çoğunlukla ilerlemiş vakalarda izlenir (22).

Dejeneratif eklem hastalıkları osteoartrit ve osteoartroz olmak üzere iki alt sınıfa ayrılır. Osteoartritte ağrı vardır, osteoartrozda ise ağrı yoktur. Kemik değişiklikleri en çok kondilde izlenir ancak mandibular fossa ya da artiküler eminensde görülebilir (23).

Kondiler kemik değişikliklerinin tipini belirleme kriterleri ise Koyama ve arkadaşlarına (24) göre aşağıdaki gibidir:

- N: Normal (Tipik morfoloji gösteren kondilin kortikal yüzeyinde proliferasyon veya kalınlaşma yok)
- F: Düzleşme (Kondilin ön-arka ve arka-ön yüzeylerinde düzleşmiş kontur)
- E: Erozyon (Kondilin kortikal yüzeyinde pürüzlü veya pürüzlü olmayan proliferasyon veya kısmi hipodens değişiklik)
- D: Deformite, marjinal proliferasyon ve osteofit (Kondil yüzeyinde proliferasyon veya kısmi hipodens değişiklik olmaksızın, gaga şeklinde deforme olmuş bir kontura sahip kondil)

- S: Erozyon, deformite, osteofit ve marjinal proliferasyon (Tip E'nin eşlik ettiği tip D)(24).

Romatoid Artrit

Romatoid artrit sinoviyal eklemlerin tahribatı, eklemlerde şişlik ve hassasiyet ile karakterize, kronik inflamatuvar bir hastalıktır. Etiyolojisi bilinmemektedir. Eklem tutulumu simetrik ve poliartikülerdir. Hastalık çoğunlukla remisyonlar ve epizodik alevlenmeler şeklinde seyreder. Romatoid artrit (RA) vakalarında temporomandibular eklem tutulumu yaygın değildir. Juvenil idiyopatik artrit (JIA) (Juvenil RA veya Still hastalığı) ise pediatrik romatizmal bir hastalıktır. TME tutulumu, JIA hastalarında % 87 kadar yüksek olabilir. Hasta klinik bir belirtisi olmadan asemptomatik olabilir. Hastadaki ilk bulgular mandibulada asimetri, sınırlı hareket açıklığı ve kondiler rezorbsiyonun neden olabileceği sınıf II maloklüzyon olabilir (18).

Hiperürisemi (Gut)

Gut, eklemlerde veya yumuşak dokuda monosodyum ürat (MSU) kristallerinin birikmesiyle karakterize iyi huylu bir hastalıktır. Metabolik artrit olarak sınıflandırılır. Gut artriti baş ve boyun bölgesini, özellikle de temporomandibular eklemi nadiren etkiler. Tedavi edilmezse gut, TME'nin tahrip olmasına neden olabilir. TME'deki artropatinin klinik belirtisi, sınırlı çene açıklığı, hafif ağrı ve eklem sesleri ile başlangıç evrelerinde belirsiz olabilir. Gut, erken teşhis ve tedavinin bu bozuklukta önemli bir etkisi olan yönetilebilir bir hastalıktır (25).

2.2.2.3.Kronik Mandibular Hipomobilité

Mandibulada açmaya zorlamakla ortaya çıkan bir ağrı vardır, onun dışında ağrısız bir kısıtlamadır. Ankiloz, kas kontraktürü veya koronoid empedans gibi sebeplere bağlı olup, sınıflandırılması da buna göre yapılır (26).

2.2.2.4. Gelişim Bozuklukları

Neoplaziler

TME de en sık görülen iyi huylu tümör osteokondrom, kötü huylu tümör osteosarkom ya da kondrosarkomdur. Bening kondiler tümörler yavaş büyüdüğünden fark edilene kadar büyük boyutlara ulaşabilir. Hastada temporomandibular eklem bölgesinde şişlik, ağrı, harekette kısıtlanma, yüzde asimetri ve etkilenmeyen tarafa deviasyon görülebilir. Koronoid proses tümörleri ise tipik olarak ağrısızdır ve hastada

giderek artan bir kısıtlanma olabilir. Meme kanseri metastazları da TME de daha çok görülür. Primer ya da metastaz sonucu oluşan TME malign tümörlerinde ise hasta asemptomatik olabileceği gibi hastada TME disfonksiyon belirtileri, ağrı, şişlik olabilir (14).

2.3. Temporomandibular Eklem Görüntüleme Teknikleri

2.3.1. Panoramik Radyografi

Panoramik radyografi dişler maksilla ve mandibulaya genel bir bakış sağladığından TME problemlerinin dişler ve çenelerden kaynaklı sorunlardan ayırt edilmesine yardımcı olur. Panoramik cihazlarının bazılarında bulunan özel TME çekim modları sayesinde TME 'nin ağız kapalı ve açık pozisyonundaki görüntüsü tek bir film üzerinde incelenebilir. Panoramik radyografide kondilin lateral ve merkezi kısımları incelenebilir. Panoramik radyografide ışınlar kondilin uzun aksına oblik şekilde ulaşır. Kondil morfolojisindeki farklılık sebebiyle görüntü distorsiyona uğramaktadır. Kafa tabanı ve zigomatik ark süperpoze olduğundan sadece belirgin yapısal değişiklikler belirlenebilir. Kondillerde asimetri, kırıklar, belirgin erozyonlar, osteofitler ve büyük deformasyonlar teşhis edilebilir (27).

2.3.2. Transkranial Radyografi

TME'in kondil ve temporal bileşenlerinin lateral yüzün sagittal yönden görüntülenir. Film kaseti görüntülenecek kondil tarafında sagittal düzleme paralel yerleştirilir. X-ışın demeti kondilin uzun aksına paralel, kondilin karşı tarafından aşağı yönde, temporal kemiğin petröz kısmına doğru pozitif 15- 25 derecelik açıyla yönlendirilir. Transkranial radyografi periapikal röntgen cihazları ile elde edildiğinden maliyeti düşük, kolay uygulanabilen, radyasyon dozu düşük bir yöntemdir. Transkranial radyografiyi manyetik rezonans görüntüleme ile karşılaştıran çalışmalarda düşük maliyeti ve kolaylıkla uygulanabilmesinden dolayı başlangıç radyografik inceleme için transkranial radyografi önerilmiştir. Bu grafi ile eklem lateral sınırı, yer değiştirmiş kondil kırıkları, kemik yapıdaki belirgin değişiklikler incelenebilir (27).

2.3.3. Transfaringeal Radyografi

Kondilin medial kısmı sagittal açıdan incelenebilir. Film kaseti görüntülenecek kondil tarafında sagittal düzleme paralel yerleştirilip, X-ışın demeti görüntülenecek

kondilin karşı tarafından sigmoid çentik doğrultusunda aşağıdan yukarı 5 derecelik açı ve anterior yönde 7 derecelik açı ile gönderilir. Bu film alınırken süperpozisyonu engellemek için hastanın ağzını olabildiğince çok açması gerekir. Kondil boynu fraktürleri ve kondilin medial kısmı inceleyebilir ancak eklem temporal bileşeni iyi izlenemez (27).

2.3.4. Transorbital Radyografi

Orbitameatal çizgi horizontal olacak şekilde, hastanın başı öne doğru 10 derece eğilir ve x -ışın demeti hastanın ön tarafından orbita ve istenen TME bölgesine doğru yönlendirilir. Film kaseti x -ışın demetine dik olarak hasta başının arkasında yerleştirilir. Hastanın ağzını olabildiğince çok açması ya da mandibulasını öne doğru kaydırması istenir. Kondil başının dejeneratif değişiklikleri ve kondil boynu kırıkları incelenebilir (27).

2.3.5. Transmaksiller görüntüleme

X – ışın demeti kondilin uzun aksına dik olarak gönderilir. Hastanın ağzı olabildiğince çok açtırılır ve x-ışın demeti tüberkülüm artikülarenin iç yüzeyine ve kondilin üst yüzeyine teğet geçecek şekilde yönlendirilir. Kondildeki belirgin dejeneratif değişiklikler, neoplaziler, anomaliler, medial yönde deplase olan kondil boynu kırıkları incelenebilir (27).

2.3.6. Submentoverteks Görüntüleme

X -ışın demeti ramusun posterior sınırına paralel olarak çene doğrultusunda yönlendirilir. Özellikle kondil başının uzun aksının açılmasının incelenmesinde faydalı olabilecek olan fasiyal asimetri, lateral olarak kondilin yer değiştirmesi, travma ve mandibulanın horizontal olarak yer değiştirdiği durumlarda kullanılabilir (27).


2.3.7. Bilgisayarlı Tomografi

Bilgisayarlı tomografi (BT) kullanımının en büyük avantajı istenmeyen distorsiyon veya süperpozisyonların önüne geçilmesidir. Ayrıca yumuşak ve sert dokuların bir arada izlenebilmesi, üç boyutlu görüntüleme ve ölçüm yapabilme diğer avantajlarından. BT, TME kemik yapılarında bulunan fraktürler, dejeneratif değişiklikler, osteofitler, ankiloz, enfeksiyon, erozyonlar, konjenital anomaliler ve tümör invazyonu değerlendirilebilir. Tekniğin dezavantajları ise hastanın aldığı

radyasyon dozunun yüksek olması, cihazın pahalı olması, çekim süresinin uzun olması, yumuşak dokuyu ayırt etmekteki yetersizliktir (28).

2.3.8. Konik Işınlı Bilgisayarlı Tomografi

Baş boyun bölgesinin incelenmesi için kullanıldığından dolayı ‘Dental Volumetrik Tomografi (DVT)’ de denilmektedir. Konik ışınlı bilgisayarlı tomografi (KIBT) cihazları BT’ye oranla 4 kat daha dar alanı görüntüleyebilir ve BT’ye oranla hasta çok daha az radyasyona maruz kalır. KIBT cihazları kraniofasiyal bölgeyi incelemek için uygun bir yöntemdir. Bu tekniğin dezavantajlarından biri yumuşak doku incelemesinde yetersiz kalmasıdır. KIBT cihazlarında çoklu rotasyonlar yerine tek bir 360° rotasyon uygulandığından ışınlama süresi, hareket artefaktı ve hastanın aldığı radyasyon dozu sınırlıdır. Yine bazı KIBT cihazlarında bulunan artefakt baskılama seçeneği metal artefaktını azaltmaya yardımcı olur. KIBT ile TME’ de bulunan fraktürler, osteofitler, skleroz, kemik gelişim anomalileri ve ankiloz değerlendirmesi yapılabilir. Yine KIBT ile TME’nin açık ve kapalı pozisyonda kondil değerlendirilmesi yapılabilir (Şekil 2.6) (28).



Şekil 2.6. TME’nin oblik sagittal KIBT görüntüsü

2.3.9. Ultrasonografi

Ultrasonografi (USG) iyonize radyasyon içermeyen, ses dalgalarıyla görüntünün elde edildiği, invaziv olmayan, düşük maliyetli ve hızlı bir görüntüleme yöntemidir.

USG ile kondil-disk ilişkisi, diskin pozisyonu, efüzyon, kapsül genişliği, osteoartroz değerlendirilebilir. Yine de görüntünün yorumlanması zordur ve tecrübe gerektirir (28).

2.3.10. Manyetik Rezonans Görüntüleme

Manyetik rezonans görüntüleme (MRG) TME diski gibi yumuşak dokuların değerlendirilmesinde kullanılabilecek en iyi yöntemdir. Artiküler eminens, zigomatik proçes ve kondil içindeki sarı kemik iliği T1 ağırlıklı görüntülerde yüksek sinyal intensitesine sahiptir. Bilaminar zon ve lateral pterygoid kastaki yumuşak dokular orta derece, disk ise düşük sinyal intensitesine sahiptir. MRG’de TME sagittal kesitlerde ağız açık ve kapalı olarak incelenir. Diskin medial ve lateral bölümünün değerlendirilebilmesi için görüntülerin koronal planda da çekilmesi gerekir (19).

2.4. Yapay Zekâ

Yapay zekâ (Artificial Intelligence-AI) bir makinenin problem çözme, nesne ve kelime tanıma, karar verme ve akıllı insan davranışlarını taklit etmek gibi karmaşık görevleri yerine getirebilmesi olarak tanımlanır (29).

McCarthy ise AI’yı “İnsan benzeri zeki makineler özellikle de zeki bilgisayar programları yapma bilimi ve mühendisliği” şeklinde tanımlamıştır (30). Bir matematikçi olan Richard Bellman’ın 1970 yılında yaptığı tanımlamaya göre ise AI insan gibi düşünce üretebilme, karar verme, öğrenme, problem çözme gibi etkinliklerin otomatik olarak gerçekleştirilmesidir (31). Alan Turing 1950 yılında yayınlanan Bilgi İşlem Makineleri ve Zekâ (Computing Machinery and Intelligence) adlı makalesinde, “Makineler düşünebilir mi?” sorusu yapay zekâ ile alakalı tartışmaların başlangıcı olmuştur (32). Alan Turing yaptığı bir çalışmada (Turing Testi) bir insan etkileşim sırasında insan-bilgisayar arasındaki farkı ayırt edemiyorsa, o zaman bilgisayarı insan kadar akıllı kabul etmek gerektiği varsayımını ortaya koymuştur (33, 34).

Medikal alanda kullanılan ilk AI örnekleri MYCIN, CASNET (Causal AS sociational NET works), PIP ve Internist-I gibi akıllı sistemlerdir. Bu sistemler çeşitli hastalıklarda manuel tanı uygulamasında etkinliklerini göstermişlerdir (35). MYCIN, 1970’lerin başında geliştirilmiştir ve bazı antimikrobiyal enfeksiyonların teşhisi ile enfeksiyona uygun ilaç tedavisi önermektedir. CASNET ise 1960’ların başında özellikle glokom tanı ve tedavisinde kullanılmıştır. İnternetin yaygınlaşmasıyla beraber 1991 yılından itibaren medikal alanda AI gelişiminde atılım olmuştur (36). Medikal yapay

zekânın şu ana kadar kullanıldığı en aktif alanlar ise teşhis ve prognozun öngörülmesidir (37).

2.5. Makine Öğrenmesi

Makine Öğrenmesi (Machine Learning, ML), AI algoritmalarının en önemli unsurudur. Makinelerin yüklenen veriler ile kalıplar yardımıyla insan müdahalesi olmadan sorunları çözmesidir (31). ML algoritmaları insan eliyle girilmiş çok sayıda veri ile doğru özel bir cevap vermek üzere eğitilmiştir. Makine öğrenimi algoritması örneğin bir radyolog tarafında eğitilmiş ise baş boyun görüntüsündeki lenf nodunu normal ya da anormal olarak ayırt edebilir ve tanıyabilir (38, 39). ML algoritmalarına ne kadar fazla veri girişi olursa o kadar iyi gelişir ve daha iyi değerlendirme yaparak spesifik cevaplar verebilir (Şekil 2.7) (40).



Şekil 2.7. Yapay zekâyı oluşturan temel kavramlar (31)

ML, AI'nın bir alt dalıdır ve algoritmalar sayesinde öğrenir. ML' nin temel tekniği ise insan beyni gibi art arda farklı girilen verileri öğrenmesi, işlemesi, görüntüleri tespit etmesi, kendi kendini düzeltmesi, sınıflandırması ve alt sınıflandırmalar yapabilmesidir (41).


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

Sinir ağları (Neural networks), insan beynini oluşturan biyolojik sinir ağlarından ilham alan bilgisayar sistemleridir. Günümüzde görüntü analizi için en çok kullanılan

algoritmalar sinir ağılarıdır (42). ANN’ de verileri bir düğüm ağından geçirirler ki bu düğüm ağı katmanlar halinde düzenlenmiştir (Şekil 2.8) (43).

Yapay sinir ağları ile biyolojik sinir ağı karşılaştırması tablo 2’ de gösterilmektedir.

Yapay sinir ağı modelini ilk olarak 1943 yılında Doktor Warren McCulloch ve matematikçi Walter Pitts “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap (A Logical Calculus of Ideas Immanent in Nervous Activity)” başlıklı makale ile ortaya çıkarmışlardır (44).




Şekil 2.8. Biyolojik sinir hücresi ve yapay sinir ağı (45)

Tablo 2.2. Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları (44)

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Yapay sinir hücresinin şematik gösterimi şekil 2.9’ da gösterilmektedir.



Şekil 2.9. Yapay sinir hücresi (44)

Şekilde anlatıldığı gibi n tane veri (X_n veri girişi) girişi olduğunda veriler ağırlıklarla çarpılır ve tüm veriler toplanır. Daha sonra ön yargı eklenir ve net yargı elde edilir. Net girdi aktivasyon fonksiyonundan geçirildikten sonra bir veri çıktısı oluşturulmuş olur (44).

2.7. Yapay Sinir Ağlarının Özellikleri (44)

- Öğrenme
- Doğrusal olmama
- Paralel çalışma
- Genelleme
- Hata Toleransı ve Esneklik
- Çok Sayıda Değişken ve Parametre Kullanma
- Eksik Verilerle Çalışma
- Uyarlanabilirlik

ANN daha çok tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme işlemlerinde kullanılmaktadır (44).

Tahmin: Burada ANN girdi değerinden çıktı tahmin etme prensibi üzerine çalışır,

Sınıflandırma: Sistemin daha hızlı sonuca varabilmesi için girdi değerlerini sınıflandırır,

Veri İlişkilendirme: Önceden öğrendiği bilgiler ile konuyu ilişkilendirerek eksik bilgiyi tamamlamasıdır,

Veri Yorumlama: Bir olay hakkında önceki girdi analizleriyle yeni yorum yapabilmesidir,


Veri Filtreleme: Bu prensipte ise kodlanan yapay ağların toplanan veriler arasında en işe yarayanı kullanmasıdır (44).

2.8. Yapay Sinir Ağ Modelleri

Yapay sinir ağı modelleri tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olmak üzere dört grupta incelenmektedir (44).

2.8.1. Tek Katmanlı Algılayıcılar


Bu ağda sadece girdi ve çıktı vardır. Tek katmanlı algılayıcıda 1 veya -1 değerini alan doğrusal bir çıktı fonksiyonu vardır. Çıktı 1 olduğunda birinci sınıfa, -1 olduğunda ikinci sınıfa kabul edilir (Şekil 2.10) (46).



Şekil 2.10. Tek katmanlı algılayıcı modeli (46)

2.8.2. Çok Katmanlı Algılayıcılar


Aktivasyon fonksiyonu yapısal olarak doğrusal değildir. Çok katmanlı algılayıcılarda birçok nöronun belli bir üstünlük içerisinde bağlandığı yapı mevcuttur (Şekil 2.11) (44).



Şekil 2.11. Çok katmanlı algılayıcı modeli (44)

2.8.3. İleri Beslemeli Yapay Sinir Ağları


Bu yapay sinir ağındaki nöronlar düzenli katmanlar halinde girişten çıkışa doğrudur. İleri beslemeli yapay sinir ağında bilgi giriş katmanı, gizli katman ve çıkış katmanına doğru sadece ileri yönde hareket eder. Bir katmanın sadece kendinden sonraki katmanla arasında bir bağ bulunur. Ağ türü basit tasarımıdır (Şekil 2.12) (10, 44).



Şekil 2.12. İleri beslemeli yapay sinir ağı modeli (10)

2.8.4. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağları doğrusal olmayan dinamik bir yapı gösterir. Burada bir nöron çıktısı ileri beslemeli yapay sinir ağında olduğu gibi sadece kendinden sonraki nöron katmanına değil kendinden önceki veya kendi katmanında bulunan bir nörona da girdi olarak bağlanabilir (Şekil 2.13) (44).



Şekil 2.13. Geri beslemeli yapay sinir ağı modeli (44)


2.9. Derin Öğrenme

Derin öğrenme makine öğrenmesinin bir alt parçasıdır ve yapay sinir ağlarının ileri düzeyli bir yaklaşımıdır. Yapay zekâ tek katmanlı sinir ağlarından çok katmanlı sinir ağlarına ve daha sonrasında derin öğrenme algoritmalarına doğru ilerleme göstermektedir. Derin öğrenme algoritmalarında çok katmanlı bir sinir ağı mevcuttur. Görüntüye ait özellik çıkarımları bu çok katmanlı yapının sinir ağı katmanlarında oluşturulmaktadır (47, 48). Makine öğrenmesinde örneğin medikal bir görüntüden lezyon tespiti yaparken görüntü bir ön işleminden geçirilir, segmentasyon, özellik çıkarımı, özellik seçimi ve sınıflandırma gibi işlemlerden geçtikten sonra lezyon tespiti yapılır. Oysa derin öğrenmede yapılan eğitim sayesinde ham veriden çıkarım yapılabilir (49, 50). Derin öğrenme algoritmaları kendi aralarında denetimli (sınıflandırma) ve denetimsiz (desen analizi) olarak ikiye ayrılmaktadır (51). Derin öğrenmede çok sayıda katman içeren ağ yapılarına derin evrimsel sinir ağları (DCNN) denilmektedir. Bu

katmanlar esas olarak daha karmaşık ve büyük görüntüleri işlemek için kullanılmaktadır (52).

2.10. Evrişimli Sinir Ağı

Derin öğrenmenin temel mimarisi evrişimli sinir ağı mimarisidir. Evrişimli sinir ağı mimarisi birden fazla eğitilebilir art arda yerleştirilmiş katmanlardan oluşur. Eğitim sürecinde giriş verileri alındıktan sonra katman katman ilerleyerek işlem yapılır. İşlem sonunda doğru sonuç ile karşılaştırma yapmak için final çıktısı verilir. Evrişimli sinir ağında hata, üretilen sonuç ile istenen sonucun farkı kadardır. Burada geri yayılım algoritması kullanılarak hata bütün ağırlıklara aktarılır ve hatanın azaltılması sağlanır. Veri girişi görüntü, ses ya da video olabilir. Daha çok görüntü sınıflandırma yapılan evrişimli sinir ağlarında, son yıllarda diğer alanlarda da çalışılmaktadır (Şekil 2.14) (53).



Şekil 2.14. Evrişimsel sinir ağının genel mimarisi (54)

2.11. Evrişimli Sinir Ağı Katmanları

2.11.1. Giriş Katmanı (Input Layer)

Evrişimli sinir ağının ilk katmanıdır. Ham veri ağıya verilir. Giriş görüntü boyutunun ağ derinliği, başarısı ve donanımsal hesaplama maliyeti açısından uygun seçilmesi gerekmektedir (53).

2.11.2. Konvolüsyon Katmanı (Convolution Layer)

Dönüşüm katmanı olarak da bilinen bu katman evrişimli sinir ağının temel katmanıdır. Dönüşüm işleminde filtreler kullanılır. Filtreler farklı boyutlarda olabilirler.

Filtreler aktivasyon haritası (özellik haritası) oluşturmak için gelen görüntülere konvolüsyon işlemi uygular. Her bir filtreye özgü özellikler aktivasyon haritasıyla aktivasyon haritasında belirlenir. Özelliklerin belirlenmesi için verinin hangi bölgesinin önem taşıdığını, ağ belirlemiş olur (53).

2.11.3. Düzleştirilmiş Doğrusal Birim Katmanı (Rectified Linear UnitsLayer(ReLU))

Evrişimli sinir ağı nöronlarının çıktıları için en yaygın şekilde devreye sokulan doğrultucu birimdir ve konvolüsyon katmanlarından sonra yer alır (53).

2.11.4. Havuzlama Katmanı (Pooling Layer)

Asıl amacı sonraki konvolüsyon katmanı için giriş boyutunu azaltmaktır ve çoğunlukla ReLu katmanından sonra yerleştirilir. “Aşağı Örnekleme” olarak da adlandırılan bu işlem veride derinlik boyutunu etkilemez. Boyuttaki azalma işlemi bilgi kaybına yol açar ancak sonraki katmanlar için daha az hesaplama yükü olduğundan ve sistemin ezberlemesinin önüne geçildiğinden bu işlem faydalıdır. Bu katmanda da belli filtreler tanımlanır. Havuzlama katmanı isteğe bağlıdır bazı evrişimli sinir ağı mimarilerinde yoktur (53).

2.11.5. Tam Bağlantılı Katman (Fully Connected Layer)

Farklı mimarilerde sayısı değişebilen bu katman kendinden önceki katmanın tüm alanlarına bağlıdır (53).

2.11.6. DropOut Katmanı

Ağın ezberlemesinin önüne geçmek için ağın bazı düğümlerinin kaldırılmasıdır (53).

2.11.7. Sınıflandırma Katmanı (Classification Layer)

Tam bağlantılı katmandan sonra gelen bu katmanda sınıflandırma işlemi yapılır. Katmandaki çıkış değeri, sınıflandırması yapılacak nesne sayısına eşittir (53).

2.12. Evrişimsel Sinir Ağının Eğitilmesi

Adım 1.

Evrişimli sinir ağı modeli oluşturulur. Tasarımcıya özgü olarak konvolüsyon katman sayısı, havuzlama katman sayısı, tam bağlantılı katman sayısı ve sınıflandırma katmanı oluşturulur (53).

Adım 2.

Filtre boyutları, filtre sayısı ve adım kayma miktarı gibi değişkenler tanımlanır. Her bir filtre için 0-1 aralığında değerler oluşturulur (53).

Adım 3.

İleri besleme aşaması denilen bu aşamada oluşturulan model giriş verisi olarak eğitim setinden bir görüntü verilir ve görüntü katmanlardan geçerek bir sonuç elde edilir (53).

Adım 4.

Aşağıdaki eşitliğe göre toplam hata değeri ağıın üretmiş olduğu sonuçlar ile hedef sonuçların farkı alınarak hesaplanır (53).

$$Toplam\ Hata = \sum_{i=1}^n \frac{1}{2} (Hedef_i - Tahmin\ Edilen_i)^2 \quad (53)$$

Adım 5.

Geriye Yayılım Algoritması (GYA) kullanılarak hesaplanan hata değeri ağıdaki tüm ağırlıklara dağıtılır. Her bir ağırlığın toplam hataya olan etkisinin hesaplanması için Stokastik Gradyan İniş (SGİ) optimizasyon algoritması kullanılır. Sınıflandırma başarısının artırılması için ağıın çıkışındaki toplam hata değeri düşürülmeye çalışılır. Bunun içinde ağırlıklar güncellenir (53).

Adım 6.

Eğitim kümesindeki bütün görüntüler için Adım 3-5 tekrarlanır (53).

2.13. Aktivasyon Fonksiyonu


Burada yapay sinir hücresi girdi verileri üzerinden işlem yaparak net çıktı elde eder. Sonuç performansını etkilediğinden fonksiyonun doğru seçilmesi önemlidir (44).

2.14. Transfer Öğrenme

Büyük veri kümeleri kullanılarak eğitilen evrişimli sinir ağı yüksek doğrulukta sınıflama yapabilmektedir. Ancak yeterli sayıda verinin bulunmaması durumunda transfer öğrenme yöntemi kullanılmaktadır. Transfer öğrenme yaklaşımları insan öğrenme modelinden yararlanır. Büyük bir veri kümesiyle eğitilmiş bir ağın ağırlıkları farklı bir veri kümesi için kullanılır (55). Bu mimarilere örnek olarak AlexNet, VGGNet, GoogleNet ve ResNet verilebilir.

2.14.1. AlexNet


Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından 2012 yılında sunulan bir derin öğrenme algoritmasıdır. Algoritmadaki katman sayısı 25'tir. ImageNet veritabanında % 80 doğruluk oranı yakalamış bir algoritmadır (Şekil 2.15) (47).



Şekil 2.15. AlexNet derin öğrenme algoritması (47)

2.14.2. GoogleNet


Doğruluk oranının % 93 olduğu, ImageNet veri tabanında yüksek başarı elde etmiş bir algoritmadır. Derin öğrenme algoritmalarından Vgg' den daha hızlı ve Alexnet'ten 12 kat daha fazla parametre içermektedir. Katman derinliği 27'dir ve mimari yapı içerisinde yaklaşık 100 katman vardır (Şekil 2.16) (47).



Şekil 2.16. GoogleNet derin öğrenme algoritması (47)

2.14.3. Vgg16


ImageNet veri tabanında %89 doğruluk yakalamış Oxford üniversitesi Görsel Geometri Grubu tarafından ILSVRC2014 yarışmasında daha iyi sonuçlar elde etmek için kullanılan 13 konvolüsyon 3 tam bağlı katmanından oluşan bir derin öğrenme algoritmasıdır (Şekil 2.17) (47).



Şekil 2.17. Vgg16 ve Vgg19 derin öğrenme mimarisi görünümü (47)

2.14.4. ResNet50

Mikro mimari modülü yapısı ile VggNet, AlexNet gibi geleneksel mimarilerden farklı bir yapıya sahiptir. 177 katmandan oluşan bir ağ yapısına sahiptir (Şekil 2.18) (47).



Şekil 2.18. ResNet bağlantı örneği (47)

2.15. Derin Öğrenme Mimarileri

2.15.1. Evrişimli Sinir Ağları (Convolutional Neural Network-CNN)

Çok katmanlı algılayıcıların bir türü olan evrişimli sinir ağları ileri yönlü bir sinir ağıdır ve hayvanların görme merkezinden esinlenilmiştir. Evrişimli sinir ağları doğal dil işleme (NLP), biyomedikal gibi farklı alanlarda uygulanmakla beraber özellikle görüntü ve ses işleme alanında uygulanmaktadır. En iyi sonuçlarda görüntü işleme alanında elde edilmiştir (51). Klasik evrişimli sinir ağlarına AlexNet, VGG, GoogleNet, ResNet, LeNet5, R-CNN, Fast R-CNN, Faster R-CNN, SSD, You Only Look Once (YOLO) örnek olarak verilebilir (56).

2.15.1.1. LeNet5:

Günümüzde yaygın olarak kullanılmayan bu mimari, 5 katmanlı bir sinir ağıdır. Çek senet tanıma, sokak tabelalarının tanınması ve el yazısı tanıma gibi çalışmalarda kullanılmıştır (56).

2.15.1.2. R-CNN:

Açılımı ‘Region-based Convolution Neural Network’ olan bu mimari evrişimli sinir ağına giriş olarak resim alındığında tüm resimde nesne aramak yerine bölge önerisi ile nesne olma ihtimali yüksek olan yerlerde nesne arama mantığına dayanmaktadır. Böylece bilgisayar için hesaplaması güç olan zorluklarla baş edebilmek için geliştirilmiştir. Bu mimaride karşılaşılan en büyük zorluk oldukça yavaş çalışmasıdır. (56).

2.15.1.3. Fast R-CNN:

R-CNN mimarisinde karşılaşılan en büyük sorun olan yavaş çalışmasını ortadan kaldırmak için geliştirilmiştir. R-CNN mimarisiyle oldukça benzer özellikler taşımaktadır. Sadece daha hızlı çalışması için geliştirilmiştir ancak bu hız yine de gerçek zamanlı işlem yapabilmek için yeterli değildir.

2.15.1.4. You Only Look Once (YOLO):

YOLO modeli 2016 yılında Joseph Redmon, Santosh Divvalai Ross Girshick ve Ali Farhadi tarafından tanıtılmıştır. OpenCV'nin People Choice Ödülünü kazanması ile büyük beğeni toplamıştır. Tek tek aşamalı modellere göre daha hızlı ve güvenli olan bu yöntem, ağı tek geçişinde hem nesne tanımlama hem de sınıflandırma işlemi yapabilmektedir (57). Bu algoritmanın milyonlarca resim üzerinden eğitilmiş bir ağ yapısı vardır ve gün geçtikçe ağ, geliştiriciler tarafından farklı hızlarda çalışabilecek sürümler ortaya çıkaracak şekilde büyütülmüştür. Bu sürümlerden en yaygın kullanılanlar YOLOv3, YOLOv4, YOLOv5 olmakla birlikte sırasıyla YOLO, YOLOv2, YOLOv3, YOLOv4, YOLOv5, YOLOX ve YOLOR sürümleri geliştirilmiştir (58).

2.15.1.4.1.YOLOv3:

Omurga, boyun ve kafa bölümlerinden oluşan bu algorithmada Darknet53, bir giriş görüntüsünden özellikleri çıkarmak için omurga olarak kullanılır. Derin bir sinir ağının omurgası, işlevi girdi görüntüsünden temel özellikleri çıkarmak olan evrişim katmanından oluşur. Boyun olarak özellik piramit ağı (FPN) kullanır. Boyun, aşağıdan yukarıya ve yukarıdan aşağıya birkaç yoldan oluşan farklı aşamalardan özellik haritalarını çıkarmak için önemli bir rol oynar ve baş, YOLO katmanından oluşur. Tek aşamalı dedektörde başın rolü, sınırlayıcı kutu koordinatlarını içeren bir vektörden oluşan son tahmini gerçekleştirmektir (genişlik, yükseklik, sınıf etiketi ve sınıf olasılığı gibi). İlk olarak görüntü, özellik çıkarımı için Darknet53'e beslenir ve ardından özellik birleştirme için özellik piramidi ağına beslenir. Son olarak, YOLO katmanı sonuçları üretir (59).


2.15.1.4.2.YOLOv4:

Bir nesne tespit algoritmasıdır ve darknet sinir ağı çerçevesinde oluşturulmuştur. Birçok uygulamada hızlı ve başarılı sonuçlar vermesi nedeniyle kullanılmaktadır. Nesne tespiti yapabilmekte ve buna ek olarak kutucuklar içerisinde gösterebilmektedir. Tüm bu işlemleri derin evrişimli sinir ağlarını kullanarak yapmaktadır. YOLOv4 ağına

veriler eğitilip aktarıldıktan sonra görüntüdeki nesnelerin hangi sınıfa ait olduğunu göstermektedir ve sonucunda bir güven skoru oluşmaktadır. Bu skor tahmin doğruluğu göstermektedir ve 0-1 arasında bir değerdir (60). Bu ağda omurga, boyun ve kafa olmak üzere üç bölümden oluşmaktadır. Omurga bölümü farklı görüntüler üzerinden özellik çıkarıp işlemektedir. YOLOv4’de alt yapısını CSPDarknet53 sinir ağı oluşturmaktadır (61). Boyun bölümü nesnelerin farklı boyutlarda algılanmasında kullanılmaktadır. Kafa bölümü ise bir önceki sürüm olan YOLO v3’e benzer olarak Dense Prediction katmanıdır. Bu bölümde nesnelerin etiketlerini, güven skorunu ve koordinatlarını içeren bir vektör oluşturulmaktadır (58).

2.15.1.4.3.YOLOv5:

Bu modelin mimarisi de omurga, boyun ve kafa bölümlerinden oluşmaktadır. Omurga olarak CSPDarknet53’ü kullanır. Omurga yapısında giriş görüntülerine özellik çıkarma işlemi yapılmaktadır ve bu bölümde bir özellik haritası oluşturulmaktadır. Bilgi akışını artırmak için boyun olarak yol toplama ağı (PANet) kullanılmaktadır. Boyun bölümü bu özellik haritalarını kafa yapılarına aktarır ve aşağıdan yukarıya, yukarıdan aşağıya olmak üzere bir kaç yoldan oluşmaktadır. Bu, modeldeki düşük seviyeli özelliklerin yayılmasını iyileştirir. PANet, nesnenin lokalizasyon doğruluğunu artıran alt katmanlardaki lokalizasyonları geliştirir. YOLOv5’teki kafa bölümü YOLOv4 ve YOLOv3 ile aynıdır. YOLOv4 algoritması darknet tarafından geliştirilmişken, YOLOv5 Pytorch Kütüphanesi tarafından geliştirilmiştir (Şekil 2.19) (59, 62).



Şekil 2.19. YOLOv5 mimarisi (59)

2.15.2. Tekrarlayan Sinir Ağları

Temelde sıralı bilgileri kullanan tekrarlayan sinir ağları, birimler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu ve bu döngü ile dinamik zamansal davranış sergilemesine olanak tanıyan bir ağıdır. Tekrarlayan sinir ağları kendi giriş belleğini girdilerin rastgele dizilerini işlemek için kullanabilir (51).

2.15.3. Uzun Kısa Vadeli Hafıza Ağları

Pratikte büyük sorunlara yol açan uzun vadeli bağımlılıkları çözmek için 1997 yılında tanıtılmıştır. Giriş, unutma ve çıkış olmak üzere üç kapısı vardır. Ayrıca Sabit Hata Döngüsü, çıkış aktivasyon fonksiyonu ve gözetleme (peephole) bağlantıları vardır. Bloğun çıktısı tekrarlanarak bloğun girişine ve tüm kapılarına bağlanır. Uzun kısa vadeli hafıza ağlarının kendi durumunu sıfırlamak için unutma kapısı ve kesin zamanlamaları öğrenmeyi kolaylaştırmak için ise gözetleme bağlantıları oluşturulmuştur (63, 64).

2.15.4. Sınırlı Boltzmann Makineleri

Boltzmann Makinalarının bir türü olan sınırlı Boltzmann makineleri, girdi seti üzerinde olasılık dağılımını öğrenebilen üretken bir rastgele yapay sinir ağı olmakla birlikte boyut indirgeme, sınıflandırma, işbirlikçi filtreleme, özellik öğrenimi, konu modelleme gibi alanlarda kullanışlı bir yöntemdir (51).

2.15.5. Derin İnanç Ağları

Görüntü tanıma ve üretme konularında uygulanan derin inanç ağları, sınırlı boltzmann makinelerinin bir yığını olarak tanımlanmaktadır. Her sınırlı boltzmann makine katmanı önceki ve sonraki katmanlarla bağlantılıdır fakat bir katmandaki düğümlerin yatay olarak iletişimi yoktur. En son katman sınıflandırma ya da denetimsiz bir öğrenme için kümeleme yapabilir (51).

2.15.6. Derin Oto-Kodlayıcılar

Diabolo ağı olarak adlandırılan Oto-kodlayıcılar denetimsiz öğrenme için kullanılan ileri beslemeli bir sinir ağıdır. Girdi verisinin sıkıştırılmış gösteriminden en iyi özelliklerin öğrenilmesi hedeflenir (51).

2.16. Derin Öğrenmede Görüntü Segmentasyonu

Yapay zekâ görüntü üzerinde analiz yapabilmek için üç farklı teknik kullanır (65).

Algılama: Bir görüntüdeki bir anormalliği tanımlamak için kullanılır (örneğin, bir nodül),

Sınıflandırma: Bir görüntü içinde bir görüntü veya lezyon atamak için bir kategoriye atanması için kullanılır (örneğin, bir BT taramasında pulmoner emboli varlığı veya yokluğu),

Segmentasyon: Bir yapıyı çalışmanın geri kalanından izole etmek için kullanılır (örneğin, bir organın sınırını belirlemek) (65). Segmentasyon tekniğinde nesneleri ve parçalarını “süper pikseller” oluşturur ve bu teknik sayesinde piksellerin her birini gözlem birimleri olarak değerlendirmek yerine daha büyük bileşenler şeklinde çalışmaya olanak sağlar (66).

2.16.1. Kodlayıcı-Kod Çözücü Modeller

Görüntü segmentasyonunda yaygın olarak kullanılır. Derin öğrenme temelli birçok segmentasyon çalışmasında da kullanılmıştır. U-Net ve V-Net iyi bilinen çeşitleridir (66-68).

2.16.2. U-Net ile Görüntü Segmentasyonu

Kodlama ve kod çözme bölümlerinden oluşan U-Net mimarisi evrişimli sinir ağı yöntemidir. Sınırlı sayıda eğitim veri seti ile başarılı bir şekilde segmentasyon yapabildiğinden dolayı özellikle medikal alanda sıklıkla tercih edilir (69-71).

2.17. Derin Öğrenme Kütüphaneleri

Çeşitli üniversiteler ve şirketlerce geliştirilmiş, derin öğrenme ve makine öğrenme çalışmalarını pratikleştirip kolaylaştırmak adına birçok hazır kütüphane bulunmaktadır. Her biri farklı bir işleve sahip kütüphanelerin çalışılacak konuya uygun olarak bilgisayara kurulması gerekmektedir (72). Tablo 2.3’te derin öğrenme kütüphaneleri ve özellikleri gösterilmektedir.

Tablo 2.3. Derin Öğrenme Kütüphaneleri (72)

Kütüphane Adı	Dili	Geliştiricisi	İşlevi
Theano	Python	MILA Lab	Çok boyutlu diziler dâhil, matematik ifadeleri etkili bir şekilde tanımlamayı ve değerlendirmeyi sağlayan bir Python kütüphanesidir.
TensorFlow	Python	Google	Veri akışı grafikleriyle verimli sayısal hesaplamalara olanak tanımaktadır.
Caffe	Python	BVLC	Caffe derin öğrenme yapısı hızlı ve modüler olacak şekilde tasarlanmıştır. Model ve optimizasyonlar kodlama yapılmaksızın ayar dosyası üzerinden yapılabilmektedir.
Keras	Python	Google	Keras kütüphanesi Tensorflow ve Theano'ya üst katman olarak yazılmış, daha kolay model geliştirmeyi sağlayan bir Python kütüphanesidir
Mxnet	Python	Amazon	Keras gibi yüksek seviye kütüphanedir, bir polyglot (çok dilli) olmasından dolayı, farklı dillerde model paylaşan ekipler için harika çözümler sunmaktadır.

Diğer derin öğrenme kütüphaneleri ise:

Pandas: Farklı formatlardaki verilerin (csv, txt, xls gibi) işlenmesi ve okunması için kullanılan açık kaynak kodlu bir kütüphane çeşididir (73).

Scikit-Learn: Kümeleme ve sınıflandırma gibi veri analizleri yapmak için kullanılan yine açık kaynak kodlu bir kütüphanedir (73).

Pytorch: Açık kaynak kodlu bir kütüphanedir. Facebook^R (Meta, Kaliforniya, Amerika Birleşik Devletleri) tarafından geliştirilmiştir. Derin öğrenme, doğal dil işleme, bilgisayarlı görme gibi alanlarda kullanılmaktadır. Bu kütüphane kullanılarak Python, Java ve C++ programlama dilleri geliştirilebilir (73). Dinamik hesaplama grafiklerinin hızlı bir şekilde oluşturabilen bu kütüphane güçlü bir grafik işlemci birimi (GPU) alt yapısına sahiptir (74).

2.18. Diş Hekimliğinde Yapay Zekâ ve Kullanım Alanları

Diş hekimliği alanında ilk yapay zekâ uygulaması 1991 yılında periapikal kemik lezyonlarını dental radyografilerden tespiti ile yapılmıştır (75). Dental radyoloji alanında ise birçok klinik öncesi çalışma ile yapay zekâ kök kanal girişlerini tam olarak bulma, vertikal kök kırıklarını tanımlama ve proksimal çürükleri belirlemede olumlu sonuçlar elde etmiştir. Başlangıçta daha çok panoramik, periapikal film, sefalometrik film gibi iki boyutlu filmler kullanılmıştır. 2009 yılında ise periapikal kistleri granülomdan ayırmak için hastaların KIBT görüntülerini kullanan bir yapay zekâ modeli önerilmiştir (29). Yine radyoloji alanında lenf nodu metastaz tespiti, osteoporoz ve Sjögren sendromu tanısında yapay zekâ kullanılmıştır. Bilgisayarlı tomografi üzerinden Sjögren sendromu tanısında % 96 oranında doğruluk tespit edilmiştir (76). Ultrasonografi görüntülerinde evrişimli sinir ağına dayanan bir yöntem ile masseter kasının segmentasyonu yüksek oranda doğrulukla elde edilmiştir (77).

Sefalometrik landmarkların otomatik lokalizasyonunda da yapay zekâ kullanılmıştır. Çoğu ortodontist manuel sefalometrik analizi zaman alıcı bulduğundan dijital bir yazılım kullanmayı tercih etmektedir (78).

Yapay zekâ teknolojisi diş çekimi sonrası post-operatif dönemdeki şişliği tahmin etmek için de yararlanılmıştır (79). Yine üçüncü molar dişlerin çekim zorluğu derecesi panoramik radyografiler üzerinde derin evrişimli sinir ağı kullanılarak değerlendirilmiştir (80).

Yapılan bir çalışmada çürük tanısı açısından yapay zekâ modeli ile tecrübeli üç diş hekiminin performansları kıyaslanmış geliştirilen sistemin diş hekimlerinden daha başarılı performans gösterdiği tespit edilmiştir (81).

Periodontoloji alanında yapılan yapay zekâ çalışmalarına bakılacak olursa periodontal hastalık sebebiyle prognozu en kötü olan dişleri tespit etmek amacıyla geliştirilen yapay zekâ modelinde %78.9'luk bir doğruluk oranı elde edilmiştir (82).

KIBT görüntüleri üzerinden yapay zekânın, implant planlamasındaki başarısı araştırılmış ve %95.3 oranında eksik diş bölgesi tespitinde başarılı olduğu bulunmuştur (83).

Yapay zekâ ile oral mukozada şüpheli bölgelerin taranması ve tespiti, lezyonların sınıflandırılması yapılarak ağız kanserlerine yatkınlığını tahmin edebileceği düşünülmektedir (84, 85).

Yapay zekâ sistemi ile panoramik radyografiler üzerinden cinsiyet tahmini ve mandibular üçüncü molar dişleri evrelendirerek yaş tahmini yapılarak adli diş hekimliği alanında da yararlanılmaktadır (86, 87).



3.MATERYAL VE METOT

3.1. Hasta Seçimi

Bu çalışmada temporomandibular eklem rahatsızlığı ve çeşitli sebeplerle İnönü Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalına gelen 290 hastadan 01.01.2018-01.06.2022 tarihleri arasında aynı standartlarda alınmış KIBT görüntüsü kullanıldı. Hastaların 191'i kadın, 99'u erkek hastalardan oluşmaktadır. Yine hastalar 18-82 yaş aralığında olup, hastaların yaş ortalaması 43,06'dır. Kemik metabolizmasını etkileyebilecek herhangi bir sistemik hastalığı, sendromu bulunan veya kemik metabolizmasını etkileyebilecek herhangi bir ilaç kullanan, çalışma alanında daha önceden geçirilmiş cerrahi operasyonu bulunan ya da çalışma alanında fraktürü olan hastaların görüntüleri çalışmaya dâhil edilmedi. Yine görüntü kalitesi kötü olan radyografik görüntüler (metal artefaktı, çekim sırasında hasta pozisyonuna ve hareketine bağlı artefaktlar vb. sebeplerle görüntüde oluşan bozukluklar) çalışmaya dâhil edilmedi. Bu çalışma için İnönü Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu'ndan onay alındı. (Tarih: 29.03.2022, Karar No: 2022/3247) Çalışma Helsinki Bildirgesi'nin ilkelerine göre yapıldı.

3.2. Radyografik Veri Setinin Elde Edilmesi

Arşivdeki tüm görüntüler için İnönü Üniversitesi Diş Hekimliği Fakültesi Ağız Diş ve Çene Radyolojisi Anabilim Dalında bulunan NewTom 5G (Verona, Italy) KIBT cihazı kullanıldı (Şekil 3.1). Hastalar standart supin pozisyonda iken alınan görüntülerin tarama süresi 18 s, görüntüleme alanı 15×12 cm; exposure süresi=3.6 s, kVp=110, mA=1–20; voxel boyutu 0.2 mm³'tür. Hastanın başı gantri içine Frankfurt düzlemi yere dik olacak şekilde ve görüntüleme sırasında ağız kapalı ve kafa sabit olacak şekilde ayarlanmıştır. (Şekil 3.1)



Şekil 3.1. Görüntülerin elde edildiği KIBT cihazı

Bu çalışmada 290 adet hastanın KIBT görüntüleri Digital Imaging and Communication in Medicine (DICOM) dosyaları şeklinde kaydedildi. DICOM dosyaları ITK-SNAP programı (<http://www.itksnap.org>) kullanılarak JPEG (Joint Photographic Experts Group) formatında sagittal kesit çerçeve görüntülerine dönüştürüldü. Elde edilen sagittal görüntülerden temporomandibular eklem başının ve boynunun olmadığı kesitler çıkarıldı. Geriye kalan 2000 adet sagittal görüntü CranioCatch etiketleme yazılımına (Eskişehir, Türkiye) yüklendi. Bu 2000 adet görüntüden 500'ü sağlıklı temporomandibular eklem olmak üzere 500'ünde düzleşme, 500 'ünde erozyon ve 500'ünde osteofit bulunan 1500 adet osteoartrit bulunan temporomandibular eklem görüntüsü mevcuttur.

3.3. Görüntü Değerlendirmesi

Bir görüntüdeki alanın tanıtılması ve nesnenin tanıtılan hangi bölgeye ait olduğunun belirlendiği işleme etiketleme denir. Hastalardan elde edilen toplamda 2000 sagittal görüntü orijinal boyutlarında kullanıldı. Sagittal görüntüler üzerinden temporomandibular eklem değerlendirilmesi 3 yıllık deneyime sahip bir araştırma görevlisi ve 10 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanı tarafından CranioCatch (Eskişehir, Türkiye) yazılımı kullanılarak İnönü Üniversitesi Diş Hekimliği Fakültesi konik ışınlı bilgisayarlı tomografi rapor odasında bulunan Precision 3640 Tower CTO BASE workstation (Intel(R) Xeon(R) W- 1250P (6 çekirdek, 12 M önbellek, temel işlemci frekansı 4.1 GHz, Maks Turbo Frekansı 4.8 GHz) DDR4- 2666, 64 GB DDR4 (4 X16GB) 2666 MHz UDIMM ECC Hafıza kapasitesi, 256 GB SSD SATA, Nvidia Quadro P620, 2 GB) (Dell, Texas, ABD) ve 27", 1920 x 1080 piksel IPS LCD monitör (Dell, Texas, ABD) kullanılarak gerçekleştirildi.

Etiketleme işlemi toplamda 2000 adet KIBT görüntüsü üzerinden her bir görüntü için bir etiketleme yapılacak şekilde serbest çizim tekniği ile belirlenerek çizilmesi şeklinde (poligon yöntemi) gerçekleştirildi. Etiketleme temporomandibular eklem osteoartritinin bulunduğu alanı ve temporomandibular eklem eklem boynu dâhil incusura mandibulaya kadar olan alanın dış sınırlarını içermektedir.(Şekil 3.2)



Şekil 3.2. Temporomandibular eklem poligonal tarzda etiketlenmesi

Temporomandibular eklem osteoartriti sınıflandırılırken Koyama ve arkadaşlarının 2007 yılında yaptığı sınıflamadan yararlanılmıştır (24). Bu sınıflandırmadan yararlanılarak toplamda 4 sınıf olarak modifiye edilmiştir;

- N: Normal, tipik morfoloji gösteren kondilin kortikal yüzeyinde proliferasyon veya kalınlaşma yok (Şekil 3.3),
- F: Düzleşme, kondilin ön-arka ve arka-ön yüzeylerinde düzleşmiş kontur (Şekil 3.4),
- E: Erozyon, kondilin kortikal yüzeyinde pürüzlü veya pürüzlü olmayan proliferasyon veya kısmi hipodens değişiklik (Şekil 3.5),
- D: Deformite, marjinal proliferasyon ve osteofit, kondil yüzeyinde proliferasyon veya kısmi hipodens değişiklik olmaksızın, gaga şeklinde deforme olmuş bir kontura sahip kondil (Şekil 3.6) (24).




Şekil 3.3.Tip N; Normal, tipik morfoloji gösteren kondilin kortikal yüzeyinde proliferasyon veya kalınlaşma yok



Şekil 3.4. Tip F; Düzleşme, kondilin ön-arka ve arka-ön yüzeylerinde düzleşmiş kontur



Şekil 3.5.Tip E; Erozyon, kondilin kortikal yüzeyinde pürüzlü veya pürüzlü olmayan proliferasyon veya kısmi hipodens değişiklik



Şekil 3.6.Tip D; Deformite, marjinal proliferasyon ve osteofit, kondil yüzeyinde proliferasyon veya kısmi hipodens değişiklik olmaksızın, gaga şeklinde deforme olmuş bir kontura sahip kondil

3.4. Derin Öğrenme Mimarisi

Bu çalışmada derin öğrenme PyTorch Kütüphanesi ve Python açık kaynak programlama dili (v.3.6.1; Python Software Foundation, Wilmington, DE, ABD) destekli transfer öğrenme yöntemi kullanılmıştır. Temporomandibular eklem segmentasyonu ve osteoartrit sınıflandırması için transfer öğrenme tekniği ile önceden Microsoft Common Objects in Context (MS COCO 2017) veri seti ile eğitilmiş bir mimari olan YOLOv5 kullanılmıştır.

YOLO nesne tespitinde kullanılan bir algoritmadır. YOLO'nun açılımı “You Only Look Once”, yani “Sadece Bir Kez Bak” tır. Bu ismin verilmesinin sebebi nesne tespitini tek seferde yapacak kadar hızlı olmasıdır. Pek çok sürümleri geliştirilen bu algoritmanın en hızlı ve güncel sürümü YOLOv5'tir (57) (88).

3.5. Model Geliştirilmesi

Model geliştirilmesi için Python açık kaynak programlama dili (v.3.6.1; Python Software Foundation, Wilmington, DE, ABD) ve PyTorch kitaplığı kullanılmıştır. Çalışmada 16 GB RAM ve NVIDIA Tesla V100 ekran kartı ile donatılmış bir bilgisayar model eğitilmesi için kullanılmıştır.


3.6. Eğitim Aşaması

Çalışmadaki veri setinin yaklaşık olarak %10'u test, %10'u doğrulama, %80'i de eğitim veri seti olarak ayrılmıştır. En uygun CNN algoritması ağırlık faktörlerini üretmek ve tahmin etmek için eğitim ve doğrulama veri setleri, modellerin başarılarının değerlendirilmesi için ise test veri seti kullanılmıştır.

Sagittal kesit çerçeveler üzerinde temporomandibular eklem segmentasyonu ve osteoartritin sınıflandırılıp etiketlendiği eğitim veri seti 1721 adet sagittal görüntüden oluşmaktadır ve bu görüntüler üzerinden 1721 adet etiketleme yapılmıştır. Veri setinde 215 görüntü test, 215 görüntü doğrulama olarak ayrılmıştır. Model eğitimlerinin tümü 500 epoch (eğitim tur sayısı) yapılarak gerçekleştirildi.

Temporomandibular Eklem Segmentasyonu

Sagittal kesit çerçeveler üzerinde temporomandibular eklem başının segmentasyonunda eğitim veri seti 1721 görüntüden oluşmaktadır. Bu eğitim veri seti üzerinden 1721 adet etiketleme yapılmıştır. Modelin eğitimi 500 epoch (eğitim tur sayısı) yapılarak gerçekleştirildi. YOLOv5 modelinin öğrenme hızı (learning rate) 0.01 değerindedir. Eğitilen modelin temporomandibular eklem segmentasyonu için oluşturduğu tahmini görüntüler şekil 3.7' de gösterilmiştir.



Şekil 3.7. YOLOv5 modelinin temporomandibular eklem segmentasyonu için oluşturduğu tahmini görüntü a) Etiketlenen görüntü, b) Yapay zekanın oluşturduğu tahmini görüntü

Temporomandibular Eklem Osteoartritinin Sınıflandırılması

Sagittal kesit çerçeveler üzerinde temporomandibular eklem osteoartritinin sınıflandırmasında eğitim veri seti 1721 görüntüden oluşmaktadır. Bu eğitim veri seti üzerinden 1721 adet etiketleme yapılmıştır. Modelin eğitimi 500 epoch (eğitim tur sayısı) yapılarak gerçekleştirildi. YOLOv5 modelinin öğrenme hızı (learning rate) 0.01 değerindedir. Eğitilen modelin temporomandibular eklem osteoartritinin sınıflandırması için oluşturduğu tahmini görüntüler şekil 3.8, 3.9, 3.10,3.11’ de gösterilmiştir.



Şekil 3.8. YOLOv5 modelinin temporomandibular eklem osteoartritinin sınıflandırılması için oluşturduğu tahmini görüntülerden sağlıklı temporomandibular eklem.



Şekil 3.9. YOLOv5 modelinin temporomandibular eklem osteoartritinin sınıflandırılması için oluşturduğu tahmini görüntülerden düzleşmiş temporomandibular eklem.



Şekil 3.10. YOLOv5 modelinin temporomandibular eklem osteoartritinin sınıflandırılması için oluşturduğu tahmini görüntülerden osteofitin olduğu temporomandibular eklem.



Şekil 3.11. YOLOv5 modelinin temporomandibular eklem osteoartritinin sınıflandırılması için oluşturduğu tahmini görüntülerden erozyonun olduğu temporomandibular eklem.

3.7. İstatiksel Analiz

Karmaşıklık matrisi, bir sınıflandırma sistemi tarafından yapılan gerçek ve tahmin edilen sınıflandırmalar hakkında bilgi içeren, makine öğreniminden bir kavramdır. Bir karmaşıklık matrisinin iki boyutu vardır, bir boyut bir nesnenin gerçek sınıfı tarafından indekslenir, diğeri ise sınıflandırıcının tahmin ettiği sınıf tarafından indekslenir (89). Bu çalışmada da model performansını değerlendirmek için karmaşıklık matrisi kullanıldı. Aynı zamanda alıcı işlem karakteristiği (Receiver Operating Characteristic Curve-ROC) eğrileri ile ROC eğrisinin altında kalan alan (Area Under Curve-AUC) hesaplandı.

3.7.1. Karmaşıklık Matris Hesaplama Prosedürü

Modelin temporomandibular eklem osteoartrit sınıflandırmasındaki başarısının değerlendirilmesi için aşağıdaki matrisler kullanıldı.

Gerçek Pozitif (TP): Osteoartrit bulunan temporomandibular eklem osteoartritli olarak teşhis edildi ve doğru sınıflandırıldı.

Yanlış Pozitif (FP): Sağlıklı temporomandibular eklem hastalıklı olarak teşhis edildi.

Yanlış Negatif (FN): Osteoartrit bulunan temporomandibular eklem sağlam teşhis edildi.

3.8. Performans Değerlendirmesi

Duyarlılık (Sensitivity-recall): Gerçek pozitif değerlerin ne kadarının doğru olduğunu duyarlılık (recall) değeri ifade eder (90).

Formülü ise şu şekildedir: $\text{Duyarlılık} = TP / (TP + FN)$

Kesinlik (Precision): Pozitif olarak tahmin edilen örneklerin gerçekte ne kadarının pozitif olduğunu kesinlik (precision) değeri ifade eder (90).

Formülü ise şu şekildedir: $\text{Kesinlik} = TP / (TP + FP)$

F1 Skoru: Kesinlik ve duyarlılık değerlerinin harmonik ortalaması ise F1-skoru (F1 score) olarak ifade edilir (90).

Formülü ise şu şekildedir: $\text{F1 skoru} = 2TP / (2TP + FP + FN)$

Birleşim Üzerinden Ortalama Kesişme: Birleşim üzerinden ortalama kesişme (IOU), bir görüntüdeki öngörülen ve gerçek kümelerin birleşimi üzerindeki kesişimin (örtüşmenin) oranı olarak tanımlanır. Örneğin, IOU eşiği 0.50 olarak ayarlanırsa, yalnızca IOU'ları ≥ 0.50 olan tahmini kümeler sunulur. Nesne sınıflandırma, algılama ve bölümlenmenin önde gelen bir uluslararası yarışması olan 2010 PASCAL Görsel Nesne Sınıfları Yarışmasında IOU eşiği olarak 0.50 değeri benimsenmiştir. Bu çalışmada da IOU eşiğini 0.50 olarak ayarlanmıştır (91).

IoU'yu hesaplamak için şu denklem kullanılır: $\text{IoU} = TP / (TP + FN + FP)$

3.9. Alıcı İşlem Karakteristiği (AİK-ROC)


ROC eğrileri özellikle radyoloji ve psikolojide tanı testlerinin değerlendirilmesi amacıyla kullanılmaktadır. Bu eğriler özellikle iki özellikli sonuç değişkeninin olduğu (nüks var-yok, remisyon var-yok, depresyon var-yok gibi) ancak karar verilirken kullanılan değişkenlerin sürekli olduğu durumlarda uygulanır. Bu sürekli değişken için ROC eğrisi olası bütün kesim noktalarını gösterir. Yine ROC eğrisi her kesim noktasında - doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif gibi farklı sonuçların sıklığı hakkında tahmin yapılmasını sağlar. Bununla beraber farklı tanı testlerinin doğru tanı koymadaki başarısının karşılaştırılmasını sağlar. ROC eğrilerinde;

x eksenini yanlış pozitif oranını, y eksenini doğru pozitif oranını ifade eder. Tanısal başarısı ifade edilen bir testin ROC analizi ile yararsız mı yoksa çok iyi bir test mi olduğuna karar verilebilir (92).




4.BULGULAR

Çalışmamızda temporomandibular eklem segmentasyonu ve temporomandibular eklem osteoartritinin sınıflandırılması için bir yapay zekâ modeli olan YOLOv5 modelinin KIBT görüntülerinden elde edilen sagittal kesitler üzerinde başarısı araştırılmıştır. Modelin performansı karmaşıklık matrisi kullanılarak değerlendirilmiştir. Temporomandibular eklem segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği aşağıdaki şekilde gösterilmiştir.(Şekil 4.1.)



Şekil 4.1. Temporomandibular eklem segmentasyonu için YOLOv5 modelinin karmaşıklık matris grafiği

Temporomandibular eklem osteoartrit sınıflandırması için YOLOv5 modelinin tahmin değerleri sırasıyla sağlıklı temporomandibular eklem için % 88, düzleşmiş temporomandibular eklem için % 70, osteofitin bulunduğu temporomandibular eklem için % 86 ve erozyon bulunan temporomandibular eklem için % 95 olarak bulunmuştur. Temporomandibular eklem osteoartrit sınıflandırması için YOLOv5 modelinin karmaşıklık matris grafiği ise aşağıdaki şekilde gösterilmektedir.(Şekil 4.2.)




Şekil 4.2. Temporomandibular eklem osteoartrit sınıflandırması için YOLOv5 modelinin karmaşıklık matris grafiği

YOLOv5 modelinin temporomandibular eklem segmentasyonu için TP, FP ve FN değerleri sırasıyla; 215, 1 ve 0 şeklindedir. Bu değerlerden hesaplanan duyarlılık, kesinlik ve F1 skorları ise sırasıyla; 1, 0.9953 ve 0.9976 şeklindedir. Yine YOLOv5 modelinin temporomandibular eklem osteoartrit sınıflandırması için TP, FP ve FN değerleri sırasıyla; 172, 52 ve 0 şeklindedir. Bu değerlerden elde edilen duyarlılık, kesinlik ve F1 skorları ise sırasıyla; 1, 0.7678 ve 0.8686 şeklindedir.

4.1. ROC (Receiver Operating Characteristic Curve) Eğrisi Grafikleri ve AUC (Area Under Curve)


YOLOv5 modelinin temporomandibular eklem segmentasyonu ve osteoartrit sınıflandırması için gösterdiği performansı değerlendirmek için ROC eğrisi ve AUC değeri hesaplanmıştır. ROC eğrisi bir sınıflandırma başarısı ölçütüdür ve doğru pozitif oranının (TPR), yanlış pozitif oranına (FPR) bölümü ile hesaplanmaktadır (93).

YOLOv5 modelinin temporomandibular eklem segmentasyonu ve osteoartrit sınıflandırması için oluşturulan ROC eğrileri aşağıdaki şekillerde gösterilmiştir.(Şekil 4.3, 4.4.)



Şekil 4.3. YOLOv5 modelinin temporomandibular eklem segmentasyonu için ROC eğrisi ve AUC değeri.

Temporomandibular eklem segmentasyonu için ROC eğrisi değerlendirildiğinde de TPR oranının 1'e yakın değerde (sol üst köşeye yakın) olduğu tespit edilmiştir. YOLOv5 modelinin temporomandibular eklem segmentasyonu için AUC değeri 0.9723 olarak elde edilmiştir.




Şekil 4.4. YOLOv5 modelinin temporomandibular eklem osteoartrit sınıflandırılması için ROC eğrisi ve AUC değeri.


YOLOv5 modelinin temporomandibular eklem osteoartrit sınıflandırması için AUC değeri 0.4970 olarak elde edilmiştir.

4.2. Precision (Kesinlik) -Recall (Duyarlılık) Eğrisi (PR Eğrisi)

Kesinlik-hassasiyet eğrisinin x eksenini ile ROC eğrisinin y eksenini TPR (Recall-Duyarlılık) anlamına gelmektedir. Grafiklerde benzer şekilde gelişmektedir. PR eğrisindeki amaç ise sağ üst köşede (1,1) olmaktır. (PR) eğrisi pozitif sınıfın performansına odaklanmaktadır (94). Temporomandibular eklem segmentasyonu ve osteoartrit sınıflandırması için PR eğrileri aşağıdaki şekillerde gösterilmektedir. (Şekil 4.5, 4.6.)



Şekil 4.5. Temporomandibular eklem segmentasyonu için PR Eğrisi.



Şekil 4.6. Temporomandibular eklem osteoartrit sınıflandırması için PR Eğrisi.

Çalışmamızda kullandığımız YOLOv5 modelinin hem temporomandibular eklem segmentasyonu hem de temporomandibular eklem osteoartrit sınıflandırması için oluşturulan PR eğrileri incelendiğinde hepsinin sağ-üst köşeye yakın değerlerde oldukları görülmüştür.

Ortalama Kesinlik (Average Precision; AP): Sıralı alım sonuçları için geri çağırma ve hassasiyeti birleştiren bir ölçüdür (95). Formülü ise aşağıda gösterilmektedir;

$$AP = \sum (duyarlılık_n - duyarlılık_{n-1}) P_{interp}(duyarlılık_{n+1}) \quad (95)$$


$$P_{interp}(duyarlılık_{n+1}) = \max p(\tilde{r}) \tilde{r} \geq rn+1 \quad (95)$$

Ortalama Kesinlik Ölçütü (Mean Average Precision; mAP): 0 ile 1 arasında değişen bu değer algılama algoritmalarını değerlendirmek için kullanılmaktadır. Sayı ne kadar yüksek olursa o kadar iyidir. Bu değer sadece 0.5'in üzerindeyse doğru pozitif olarak kabul edilmektedir (95). Formülü ise aşağıda gösterilmektedir;

$$mAP = \frac{1}{N} \sum_i AP_i \quad (95)$$


Temporomandibular eklem segmentasyonu için elde edilen mAP değeri 0.995 olarak bulunmuştur. Temporomandibular eklem osteoartrit sınıflandırması için bulunan mAP değerleri ise sırasıyla; sağlıklı eklem için 0.934, düzleşmiş eklem için 0.856, osteofit bulunan eklem için 0.903, erozyon bulunan eklem için 0.948 ve tüm sınıflar için 0.910 olarak bulunmuştur.

Temporomandibular eklem segmentasyonu için yaptığımız çalışma sonuçlarının grafiksel gösterimi aşağıda gösterilmiştir;




Şekil 4.7. Temporomandibular eklem segmentasyonu için yaptığımız çalışma sonuçlarının grafiksel gösterimi

Yine temporomandibular eklem osteoartrit sınıflandırması için yaptığımız çalışma sonuçlarının grafiksel gösterimi aşağıda gösterilmiştir;




Şekil 4.8. Temporomandibular eklem osteoartrit sınıflandırması için yaptığımız çalışma sonuçlarının grafiksel gösterimi


Temporomandibular eklem YOLOv5 modeli ile segmentasyonunda elde edilen F1 güven eğrisi, kesinlik güven eğrisi ve duyarlılık güven eğrisi sırasıyla şekil 4.9., 4.10. ve 4.11. da gösterilmiştir.



Şekil 4.9. Temporomandibular eklemin YOLOv5 modeli ile segmentasyonunda elde edilen F1- güven eğrisi.




Şekil 4.10. Temporomandibular eklemin YOLOv5 modeli ile segmentasyonunda elde edilen kesinlik-güven eğrisi.




Şekil 4.11. Temporomandibular eklemin YOLOv5 modeli ile segmentasyonunda elde edilen duyarlılık-güven eğrisi.


Temporomandibular eklemin YOLOv5 modeli ile osteoartrit sınıflamasında elde edilen F1 güven eğrisi, kesinlik güven eğrisi ve duyarlılık güven eğrisi sırasıyla şekil 4.12, 4.13. ve 4.14. da gösterilmiştir.



Şekil 4.12. Temporomandibular eklemin YOLOv5 modeli ile osteoartrit sınıflamasında elde edilen F1- güven eğrisi



Şekil 4.13. Temporomandibular eklemin YOLOv5 modeli ile osteoartrit sınıflamasında elde edilen kesinlik- güven eğrisi



Şekil 4.14. Temporomandibular eklemin YOLOv5 modeli ile osteoartrit sınıflamasında elde edilen kesinlik- güven eğrisi

YOLOv5 modelinin performansını değerlendirmek için kullandığımız değerlerden biride doğruluk değeridir. Temporomandibular eklem segmentasyonu için bulunan doğruluk değeri 0.9953 olarak bulunmuştur. Temporomandibular eklem osteoartrit sınıflandırması için elde edilen doğruluk değeri ise 0.7678 olarak bulunmuştur.

5.TARTIŞMA

AI, öğrenme ve problem çözme yeteneği gibi geleneksel olarak insan zekâsı ile ilişkili görevleri yerine getirmek için bilgisayar algoritmalarının geliştirilmesine adanmış bir bilgisayar bilimi dalıdır (42). Buna makine öğrenimi, temsili öğrenme ve derin öğrenme dâhildir (65). Son yıllarda çok çeşitli endüstrilerde aktif olarak uygulanan yapay zekâ, birçok araştırmacı için aktif bir ilgi alanıdır. Diş hekimliği de bu eğilimin bir istisnası değildir ve yapay zekâ uygulamaları özellikle oral ve maksillofasiyal radyoloji alanında umut vericidir.

Oral ve maksillofasiyal radyolojide yapay zekâ üzerine yapılan son araştırmalarda, esas olarak görüntü sınıflandırma, algılama, segmentasyon, kayıt, üretim ve iyileştirme yapabilen konvolüsyonel sinir ağları kullanılmıştır (96). Yapay zekâ kullanımı özellikle oral ve maksillofasiyal radyoloji alanında birçok avantaja sahiptir. Örneğin yapay zekâ çeşitli paternleri tanımlamak, davranış veya olayları tahmin etmek veya nesneleri kategorilere ayırmak için güçlü bir araçtır. Hassas programlama yoluyla radyoloji departmanının iş akışını iyileştirebilir, randevuları kaçırma riski en yüksek olan hastalar belirleyebilir ve kişiye özel muayene protokolleri oluşturabilir (42). Doğrudan tıbbi verilerle işlem yapan yapay zekâ, bilişsel önyargıdan kaynaklanan hataların önlenmesine yardımcı olabilir (97).

Bizim çalışmamızda da yapay zeka sistemi kullanılarak konik ışınlı bilgisayarlı tomografi görüntülerinde temporomandibular eklem segmentasyonu ve temporomandibular eklem osteoartritinin sınıflandırılması yapılmaya çalışılmıştır.

Oral ve maksillofasiyal radyoloji alanında görüntüleme yöntemleri üzerine yapılan yapay zekâ çalışmalarına bakacak olursak; yapılan bir çalışmada 206 adet dijital periapikal film üzerinden çürük, alveolar kemik kaybı ve interradyiküler radyolusensi üç uzman tarafından etiketlendi ve üç adet mimarın (U-Net, XNet, SegNet) bu etiketlemeleri tespit etme başarıları karşılaştırıldı. U-Net mimarisi ve varyantı, tüm ölçümlerde Xnet ve SegNet'ten önemli ölçüde daha iyi performans gösterdi. Çalışmanın sonucu olarak derin öğrenmenin dijital periapikal filmlerin analizi için potansiyele sahip olduğu bulunmuştur (98).

Yine bir başka çalışmada derin evrişimli sinir ağı algoritmasına dayalı bilgisayar destekli bir tespit sistemi geliştirmek ve bu sistemin periodontal olarak riskli dişlerin

teşhisi ve tahmini için potansiyel faydasını ve doğruluğunu değerlendirmek için periapikal radyografik görüntüler kullanıldı. Periapikal radyografik veri seti eğitim, doğrulama ve test veri setlerine bölünmüştür. Derin öğrenme algoritması ile periodontal olarak riskli dişler için tanısal doğruluk premolarlar için %81.0 ve molarlar için %76.7 idi. Klinik olarak şiddetli periodontal hastalıklı olarak teşhis edilen 64 premolar ve 64 molar diş kullanıldığında, çekimi tahmin etme doğruluğu, premolarlar için %82.8 ve molarlar için %73.4 idi. Python'da Keras sistemine dayanan derin CNN algoritması kullanılan bu çalışma, yapay zekânın periodontal olarak riskli dişlerin teşhisini ve öngörülebilirliğini değerlendirmek için yararlı olduğunu göstermiştir (82).

Periodontitisli ve farklı alveoler kemik kaybı derecelerine sahip 31 adet dişin periapikal filmleri üzerinde yapılan bir yapay zekâ çalışmasında sonuçlar, yapay zekânın periodontitisli dişlerin periapikal radyografi görüntülerinde alveolar kemik kaybı alanlarını etkili bir şekilde lokalize edebileceğini ve dolayısıyla diş hekimleri için periodontitis hastalarında kemik kaybının derecesini değerlendirmede faydalı olacağını göstermektedir (99). Periapikal ve panoramik filmlerden oluşan toplamda 200 adet anonim görüntü üzerinde yapılan bir çalışmada ise diş çürüğünün tedavisini tahmin etmek için bir derin öğrenme modeli önerilmiştir. Yaklaşım esas olarak Florür, Dolgu ve Kanal tedavisi olmak üzere üç tür tedaviyi öngörmektedir. Sistemi geliştirmek için Python üzerinde Keras API kullanılmıştır. Modelin genel doğruluğu %87'dir. En iyi tahmin %98 ile flor tedavisi olurken, bunu %88 ile kanal tedavisi izledi. Dolgu tedavisi, %77 oranında daha düşük sınıflandırma doğruluğu vermiştir (100).

130 adet bite-wing radyografi üzerinde çürük teşhisi ile ilgili yapılan bir yapay zekâ çalışmasında 5 adet gözlemci ile beraber değerlendirme yapılmış ve oluşturulmaya çalışılan otomatik çürük tespit programının çok tutarlı olmadığı ve bir yüzeydeki çürük durumu hakkında farklı görüşler sağladığı sonucuna varılmıştır. Çürük teşhisinde gözlemciler arası anlaşma program kullanılarak geliştirilememiştir (101). 1200 adet bitewing radyografi üzerinden diş segmentasyonu amaçlanan bir başka çalışmada CNN türünden olan Bölgesel Tabanlı Evrişimli Sinir Ağı (R-CNN) kullanılmıştır. Dişlerin bölgelerinin tespiti ve otomatik segmentasyonu için R-CNN ağı türünden olan Mask R-CNN ağı kullanılmıştır. Derin öğrenme kütüphanelerinden olan Keras ve TensorFlow başta olmak üzere Python programlama diline ait kütüphanelerden yararlanılmıştır. Mimari olarak ResNet-101 kullanılmıştır. Ve sonuç olarak ortalama genel hassasiyet değeri %97.49 olarak elde edilmiştir (102).

Panoramik radyografiler maksiller ve mandibular dental arkları ve komşu anatomik yapıları tek bir görüntüde incelenmesine imkân tanıyan bir görüntüleme yöntemidir. Ağız açıklığında kısıtlanma olan ya da intraoral teknikleri tolere edemeyen hastalarda uygulanabilmesi, hızlı ve kolay uygulanan bir yöntem olması, , intraoral tüm ağız radyografi serisine göre daha düşük radyasyon dozu ile görüntünün elde edilmesi ve kolay anlaşılır olması nedeniyle diş hekimliğinde çok sık kullanılan bir görüntüleme yöntemidir (103).

Panoramik radyografiler ile yapılan yapay zekâ çalışmalarına bakacak olursak 153 adet panoramik radyografi ile yapılan bir yapay zekâ çalışmasında diş eksiklikleri tespit edilmeye çalışılmıştır. Radyografik görüntülerin 99'u tam dişli ve 54'ü eksik dişli hastalara aittir. Eğitim ve doğrulama veri seti 76 ve test veri seti 32 görüntüden oluşmaktadır. Açık kaynak kodlu python programlama dili ve OpenCV, NumPy, Pandas ile Matplotlib kütüphanelerinden yararlanılmıştır. Veri setleri transfer öğrenimi kullanılarak eğitilmiş ve mimari olarak Inception v3 mimarisi kullanılmıştır. Sonuç olarak görüntülerin modeli tahmin etmesi ile çıkan başarı oranı % 94,7'dir (104). Başka bir çalışmada yetişkinlerden rastgele seçilmiş 1352 adet panoramik radyografi üzerinden yapay zekâ ile diş tespiti ve numaralandırma yapılması amaçlanmış ve sistemin performansını değerlendirmek ve uzmanlarla karşılaştırmak için 222 görüntüden oluşan ayrı bir test seti kullanılmıştır. Diş numaralandırma, tespit edilen diş görüntülerini FDI (Federation Dentaire Internationale) sistemine göre sınıflandırmıştır. Diş tespiti için Faster R-CNN modelini kullanılmıştır. Diş tespiti için duyarlılık 0.9941 ve kesinlik 0.9945 olarak, diş numaralandırma için duyarlılık 0.9800 ve özgüllük 0,9994 olarak bulunmuştur. 5 adet uzman ile yapılan karşılaştırma sonucunda ise uzmanların diş tespiti için duyarlılığı 0.9980 ve kesinliği 0.9998 olarak, diş numaralandırma için duyarlılığı 0.9893 ve özgüllüğü 0.9997 olarak bulunmuştur (105).

Bir başka panoramik ile yapılan yapay zekâ çalışmasında 183 kişiye ait 261 panoramik radyografi üzerinde çalışılmıştır. Bu radyografiler ile yapay zekaya beş farklı restorasyon tipi öğretilerek dental görüntülerden kimlik tespiti yapılması amaçlanmıştır. Destek Vektör Makinesi (DVM) ve Rastgele Orman yöntemleri kullanılan bu çalışmada Rastgele Orman Metodu %94, DVM ise %96 başarımlar göstermiştir (106). Başka bir çalışmada diş hekimliği öğrencilerinin eğitimi için yapay zekâ destekli web tabanlı radyolojik görüntü analiz ve etiketleme uygulaması olan DentiAssist geliştirilmiştir. Panoramik diş görüntüleri ile on öğrenci çalışmaya dâhil edilmiştir. AI tabanlı analizde,

dişleri tespit etmek ve bölmek için Mask R-CNN kullanılmıştır. DentiAssist yazılımının etiketleme modülü kullanılarak, üç maksillofasiyal radyolog tarafından kesin olarak etiketlenen 649 eğitim ve 279 doğrulama verisi sisteme girilmiştir. Eşit sayıda 100 test görüntüsü kullanılarak, öğrenci ve yapay zekâ karşılaştırması sonucunda ortalama kesinlik %97.75 ölçülmüştür. Radyolog ve yapay zekâ karşılaştırmasında ise %99.02 başarı elde edilmiştir (107).

Panoramik radyografiler üzerinden periodontal kemik kaybının radyografik tespiti için yapılan bir yapay zekâ çalışmasında rastgele seçilmiş 85 adet panoramik radyografi üzerinden kırılmış 2001 adet görüntü kullanılmıştır. Karşılaştırma için altı diş hekimi görüntüleri değerlendirmiştir. Sonuç olarak CNN'nin ortalama sınıflandırma doğruluğu 0.81 (0.02)'dir. Ortalama duyarlılık ve özgüllük sırasıyla 0.81 (0.04), 0.81 (0.05)'dir. Diş hekimlerinin ortalama doğruluğu 0.76 (0.06)'dır, ancak CNN, diş hekimlerine kıyasla istatistiksel olarak üstün olamamıştır ($p=0.067/t$ -testi). Diş hekimlerinin ortalama duyarlılık ve özgüllüğü sırasıyla 0.92 (0.02) ve 0.63 (0.14) olarak bulunmuştur. Sınırlı miktarda radyografik görüntü seti üzerinde eğitilmiş bir CNN, panoramik radyograflarda periodontal kemik kaybını değerlendirmek için diş hekimleri ile en azından benzer bir ayırım yeteneği gösterdiği sonucuna varılmıştır (108).

Panoramik radyografide taurodontizmlı dişleri teşhis etmek için CNN tabanlı AI modelinin işlevini geliştirmek ve değerlendirmek amacıyla yapılan bir çalışmada Pytorch uygulanmış bir U-Net modeli kullanılmıştır. Otomatik taurodont diş segmentasyon modelleri geliştirmek için 13 yaşın üzerindeki 434 anonimleştirilmiş, karışık boyutlu panoramik radyografi görüntüsünden yararlanılmıştır. Model performansını belirlemek için Karışıklık Matrisi kullanılmıştır. Taurodont diş segmentasyonunun duyarlılık, kesinlik ve F1-skor değerleri sırasıyla 0.8650, 0.7898 ve 0.8257 olarak bulunmuştur. CNN sisteminin taurodontizmlı dişleri tespit etme yeteneğinde tatmin edici düzeyde sonuçlar elde edilmiştir (109). Bizde çalışmamızda benzer olarak Pytorch Kütüphanesi kullandık ve yine model performansını değerlendirmek için Karmaşıklık matrisi kullandık

90 adet panoramik radyografi üzerinden yapılan bir yapay zekâ çalışmasında ise maksiller sinüs ve mandibular kanal panoptik segmentasyon denilen bir yöntem ile tespit edilmeye çalışılmıştır. Modelin maksiller sinüs ve mandibular kanalı segmentlere ayırmada başarılı olduğu ve diş hekimlerine yardımcı olabileceği sonucuna varılmıştır (110). Derin evrişimli sinir ağı tabanlı tanı sisteminin panoramik radyografilerde

osteoporoz tanı performansını, oral ve maksillofasiyal radyologlarla karşılaştırarak değerlendiren bir çalışmada 1268 adet kadının panoramik radyografisi kullanılmıştır. 10 yıldan fazla deneyime sahip oral ve maksillofasiyal radyologlar, 1268 kadının panoramik radyografilerini incelediler ve mandibular alt korteksin kortikal erozyonu gözlemlendiğinde osteoporoz tanısı koydular. Buna göre kadınlardan 635'inde osteoporoz vardı ve 633'ünde osteoporoz yoktu. Panoramik radyograflarda osteoporozun saptanmasında konvolüsyonel sinir ağını eğitmek, doğrulamak ve test etmek için, tek sütunlu derin evrişimli sinir ağı (SC-DCNN), veri artırılmalı SC-DCNN ve çok sütunlu derin evrişimli sinir ağı (MC-DCNN) kullanıldı. SC-DCNN, SC-DCNN (Veri artırılmalı) ve MC-DCNN kullanılarak elde edilen eğrinin altındaki alan (AUC) değerleri sırasıyla 0.9763, 0.9991 ve 0.9987 olarak bulunmuştur. Uygulanan sistem, osteoporozun saptanmasında deneyimli oral ve maksillofasiyal radyologlarla yüksek bir uyum göstermiştir (111).

Ortodontik tedavilerin üç boyutlu değerlendirilmesini sağlamak amacıyla ortodontik alçı modellerinden ve panoramik radyografilerden yararlanılmıştır. Tek tek kuron modeller çıkartmak ve diş arkları, diş aralıkları, diş eti kenarlarını tespit etmek için yarı otomatik segmentasyon yöntemi uygulanmıştır. Sadece çalışma modelleri ve panoramik radyografiler ile tomografi taraması yapılmadan 3 boyutlu kök bilgisi sunabilme özelliği, çoğu ortodontik vakada yararlı olarak bulunmuştur (112).

Başka bir çalışma toplamda 858 panoramik radyografi üzerinde temporomandibular eklemi normal ve osteoartrit vakalarına göre sınıflandırmak için önceden eğitilmiş modelleri kullanarak bir teşhis destek aracı geliştirmeyi amaçlamıştır. Temporomandibular eklem osteoartrit teşhisi için Schiffman (113) ve arkadaşlarının sınıflandırmasından yararlanılmıştır. Osteoartrit teşhisi için subkondral kistler, yüzey erozyonu veya osteofitlerden en az biri olmalıdır. Bunlar olmadan sadece düzleşme veya skleroz varlığı temporomandibular eklem osteoartriti için belirsiz kabul edilmiş ve hariç tutulmuştur (114). Bizim çalışmamızda da benzer olarak temporomandibular eklem osteoartrit sınıflaması yapılmıştır. Ancak biz eklemi KIBT görüntüleri üzerinde değerlendirdik ve osteoartrit sınıflamasında Koyama (24) ve arkadaşlarının sınıflandırmasından yararlanarak temporomandibular eklemi sağlıklı, düzleşme, erozyon ve osteofit olmak üzere dört ayrı sınıfa ayırdık. Yapılan panoramik çalışmada 518 hastanın sol ve sağ kondillerinden elde edilen 858 görüntünün 395'i normal, 463'ü osteoartritli görüntüden oluşmaktadır. Veriler rastgele eğitim, doğrulama ve test

kümelerine ayrılmıştır (6:2:2). Transfer öğrenme modelleri olarak önceden eğitilmiş Resnet152 ve EfficientNet-B7'yi kullanılmıştır. ResNet-152 ve EfficientNet-B7'nin sınıflandırma doğrulukları sırasıyla 0.87 ve 0.88 olarak bulunmuştur (114). Bizim çalışmamızda 290 hastadan elde edilen 2000 adet KIBT görüntüsü kullanılmıştır. Temporomandibular eklem osteoartritin (TMEOA) sınıflandırması için YOLOv5 mimarisi kullanılmıştır ve elde edilen doğruluk değeri 0.76 olarak bulunmuştur. Sonuç olarak panoramik görüntülerle yapılan ilgili çalışmada uygulanan yapay zekâ modelinin panoramik radyografiler üzerinde temporomandibular eklem osteoartrit teşhisi için bir tarama aracı olarak kullanılabileceği sonucuna varılmıştır (114).

Benzer bir çalışmada panoramik radyografiler üzerinde temporomandibular eklem osteoartrit teşhisi için bir yapay zekâ modeli geliştirmek ve bunu bir uzman ile karşılaştırmak amaçlanmıştır. Karas'ın ResNet modeli kullanılarak bir AI modeli geliştirilmiştir ve görüntüleri üç kategoride sınıflandırmak için eğitilmiştir (normal, belirsiz osteoartrit ve osteoartrit). Çalışmada KIBT ile teşhisi doğrulanmış 1189 adet panoramik radyografi kullanılmıştır. Yapay zekâ 3 kategori ile geliştirildiğinde model performansı tatmin edici bulunmamıştır. Belirsiz osteoartrit kategorisi çıkarıldıktan sonra yapay zekâ bir uzmana benzer bir şekilde temporomandibular eklem osteoartriti teşhisi koymuştur ve en çok bu şekliyle KIBT ile uyumlu bulunmuştur. Elde edilen değerler ise doğruluk: 0.78, duyarlılık: 0.73 ve özgüllük: 0.82 olarak belirtilmiştir. Çalışmadaki veriler için tekrarlama sayısı 700 epoch olarak uygulanmıştır (115). 2000 adet sagittal KIBT görüntüsü üzerinde temporomandibular eklem osteoartriti 4 kategoride sınıflandırdığımız çalışmamızda ise epoch sayısı 500 idi ve elde edilen doğruluk ve duyarlılık sayıları sırasıyla 0.7678 ve 1 olarak bulunmuştur.

Paranasal sinüs radyografilerinden cinsiyet ve yaş tahmini yapmak amacıyla yapılan bir yapay zeka çalışmasında retrospektif olarak anonim 4160 radyografi kullanılmıştır. Yaş grupları 20–39, 40–59, 60+ yıl olarak üç gruba ayrılmıştır. ResNet-152 ve DenseNet-169 mimarilerini benimseyen iki CNN modeli uygulanmıştır. Cinsiyet tahmini için ResNet-152, DenseNet-169'dan biraz daha iyi performans göstermiştir. (Doğruluk = %98.0, duyarlılık = %96.9, özgüllük = %98.7 ve AUC = 0.939). Yaş tahmini için, DenseNet-169 modeli yaş gruplarını tahmin etmede biraz daha doğru bulunmuştur. (%77.6±1.5'e karşı %76.3±1.1). Derin öğrenme modeli, paranasal radyografi görüntülerine dayalı olarak cinsiyeti ve yaşı tahmin edebilmiştir. Bu nedenle,

klinalerde hastanın yanlış tanımlanması riskinin azaltılmasına yardımcı olabileceđi sonucuna varılmıştır (116).

Ağız ii fotoğraflardan yaralanarak yapılan yapay zekâ alıřmaları zellikle oral lezyonların tanısında umut vericidir. Yapılan bir alıřmada ağız ii fotoğraflar kullanarak oral liken planus lezyonlarını tanımlamak iin derin bir ğrenme yaklařımı geliřtirmeyi amalamıştır. 65 sađlıklı ve 72 oral liken planus lezyonu bulunan bukkal mukozanın anonim retrospektif fotoğrafları CranioCatch programı (CranioCatch, Eskiřehir, Trkiye) kullanılarak tanımlanmıştır. Bu alıřmada tm grntler uzmanlar tarafından tekrar kontrol edilmiř ve dođrulanmıştır. alıřmada, derin ğrenme yaklařımı olan Tensorflow ile uygulanan Google Inception V3 mimarisi kullanılarak bir yapay zekâ modeli geliřtirilmiştir. AI derin ğrenme modeli, hem sađlıklı hem de hastalıklı mukoza iin tm test grntlerinin %100 bařarı oranıyla sınıflandırılmasını sađlamıştır (117). Yapay zekâ kullanılan bařka bir fotoğraf alıřmasında ise liken planus ve lkoplaki ayrımı yapılması amalanmıştır. alıřmaya histopatolojik olarak kesin tanısı konmuř 21 liken planus, 21 lkoplaki ve 21 sađlıklı gnll dhil edilmiştir. alıřma grubunun yař ortalaması 58'dir. Tm katılımcıların ağız ii fotoğrafları bukkal mukozaya dik olarak ekilmiştir. Mmkn olan maksimum kontrastı elde etmek iin bir filtre uygulanmış ve ardından grntlerin histogramlarını eřitlemek iin seviye araları kullanılmıştır. Daha sonra grntler 8 bit gri tonlamaya dnřtrlmřtr. Otomatik tanı sisteminin etkinliđi, Bayesian sınıflandırıcısı olarak adlandırılan bir sinir ađı kullanılarak kontrol edilmiştir. Ağız ii makro fotoğraflar ile dijital doku analizine dayalı olarak ağız mukozasında lkoplaki ve liken planusun ayırıcı tanısının mmkn olduđu sonucuna varılmıştır. Bu yntem akıllı telefon uygulamaları geliřtirmek iin kullanılabilir ve ayrıca pratisyen diř hekimlerinin bir uzmanla grřmeden klinik tanı koymaları iin yararlı bir ara olabilir (118).

Yapılan retrospektif bir alıřmada 2000-2017 yılları arasında cerrahi tedavi uygulanan, analize uygun 255 oral skuamz hcreli karsinoma (SCC) hastasında derin ğrenme temelli sađ kalım tahmin yntemini uygulanmıştır. Derin ğrenme tabanlı bir hayatta kalma tahmin algoritması olan DeepSurv kullanılarak hayatta kalma tahmini, rastgele hayatta kalma ormanı (RSF) ve Cox orantılı tehlike modeli (CPH) ile karřılařtırılmıştır. DeepSurv,  model arasında en iyi performansı gstermiştir. DeepSurv'n performansı, eklenen zelliklerle srekli olarak iyileřtirilmiştir. Bu nedenle, derin ğrenmeye dayalı hayatta kalma tahmininin dođruluđu artırılabilir ve

klinisyenlere hem tedavi seçeneklerini seçmede hem de gereksiz tedavilerden kaçınmada rehberlik edebilir (119).

Maksillofasiyal yapıların üç boyutlu değerlendirilmesi için 90'lı yılların sonunda konik ışınli bilgisayarlı tomografi görüntüleri geliştirilmiştir. Dünyada olduğu gibi ülkemizde de konik ışınli bilgisayarlı tomografilerin diş hekimliği fakültelerinde kullanımı yaygınlaşmıştır. Konik ışınli bilgisayarlı tomografilerin birçok durumda iki boyutlu görüntülemeden daha üstün olduğu belirtilmiştir. Konik ışınli bilgisayarlı tomografi görüntüleri endodontik tedavi öncesinde dilerasyon, kök sayı anomalileri, dens in dente gibi durumlarda, ortodontik tedavi öncesi değerlendirmede, dental implant uygulamalarında, gömülü diş, süpernumere diş, yabancı cisimlerin konumlarının belirlenmesi ve anatomik yapılarla ilişkisinin değerlendirilmesinde kullanılmaktadır. Ayrıca temporomandibular eklem ve çevre kemik yapıların değerlendirilmesinde kullanılabilir (120).

Tanısal performansı ve kullanımının yaygınlaşmasıyla konik ışınli bilgisayarlı tomografi görüntülerinin kullanıldığı yapay zeka çalışmaları da yaygınlaşmaya başlamıştır. Bizim çalışmamızda temporomandibular eklemin segmentasyonu ve osteoartrit sınıflandırması için KIBT görüntüleri kullanılmıştır. Yapılan bir çalışma gömülü üçüncü büyük azı dişlerini KIBT görüntüleri değerlendiren yapay zekâ uygulamasının tanısal performansını değerlendirmektedir. Bu retrospektif çalışmaya toplam 130 üçüncü molar diş (65 hasta) dahil edilmiştir. Gömülü dişlerin tespiti, sayıları, dişlerin kök/kanal sayıları, komşu anatomik yapılarla (inferior alveolar kanal ve maksiller sinüs) ilişkisi, gözlemci ve AI uygulaması arasında karşılaştırılmıştır. Görüntülerin manuel olarak incelenmesi, KIBT yazılım sistemi kullanılarak tek bir dentomaksillofasiyal radyolog tarafından yapılmıştır. Gömülü diş sayıları, dişlerin kök/kanal sayıları, komşu anatomik yapılarla (inferior alveolar kanal ve maksiller sinüs) ilişkisi kaydedilmiştir. Bu adımdan sonra dosyalar derin evrişimli sinir ağına (Diagnocat, Inc.) rastgele yüklenmiştir. U-net benzeri bir mimari kullanılmıştır. Toplamda 112 diş (%86.2) AI tarafından gömülü olarak tespit edilmiştir. 99 dişte (%78.6) kök sayısı, 82 dişte (%68.1) kanal sayısı doğru tespit edilmiştir. Inferior alveolar kanalın belirlenmesinde mandibular gömülü üçüncü molar dişlerle (kappa: 0.762) ve ayrıca kök saptama sayısı (kappa: 0.620) ilişkili olarak iyi bir anlaşma bulunmuştur. Benzer şekilde, gömülü maksiller üçüncü molar dişler ve maksiller sinüs ilişkisi ile ilgili olarak mükemmel bir uyum yakalanmıştır (kappa: 0.860). Maksiller

molar dişlerin kanal sayısı tespiti için, gözlemci ve AI muayeneleri arasında orta derecede bir uyum bulunmuştur (kappa: 0.424). Yapay Zekâ uygulaması, gömülü üçüncü büyük azı dişlerinin tespitinde ve anatomik yapılarla olan ilişkilerinde yüksek doğruluk değerleri göstermiştir (121).

17 adet KIBT görüntüsü kullanılan bir yapay zekâ çalışmasında ise invaziv olmayan bir yöntemle ile periapikal kist ve granülom ayrımı yapılmaya çalışılmıştır. Biyopsi ve KIBT tanıları ile karşılaştırma yapılan bu çalışma %94,1 doğru sınıflandırma oranı göstererek önerilen yöntemin etkinliğini göstermiştir (122). Maksillofasiyal kistlerin (radiküler kist, dentigeröz kist, keratokistik odontojenik tümör) otomatik segmentasyonunu amaçlayan bir çalışmada asimetri analizine dayalı otomatik bir yöntem önerilmiştir. Bu yaklaşımın temeli, normal baş ve yüz yapısının orta sagittal düzleme göre kabaca simetrik olmasıdır. Kistler ve tümörler tipik olarak bu simetriyi bozar. Çalışma çeşitli görüntü alma merkezlerinden toplanan çeşitli çene kistlerini içeren 97 KIBT görüntüsünden oluşmaktadır. Yapılan çalışmanın sonucunda yüksek gerçek pozitif değerler elde edilmiştir. Bu da yöntemin etkili olduğunu göstermiştir (123).

Başka bir çalışmada keratokistik odontojenik tümörün daha hızlı otomatik segmentasyonunu sağlayan yeni bir araç olan Smartbrush'ı sunmaktadır. Çalışmaya keratokistik odontojenik tümör tanısı kesinleşmiş 38 hastanın üç boyutlu görüntüleri dâhil edilmiştir. Tümörler manuel segmentasyon, eşik tabanlı segmentasyon ve Smartbrush kullanılarak segmentlere ayrıldı. Her üç yöntem de kullanılabilirlik, zaman ve doğruluk açısından karşılaştırıldı. Sonuçlar, Smartbrush kullanarak segmentasyonun önemli ölçüde daha hızlı olduğunu göstermektedir (124). Başka bir çalışmada konka büllozayı tanımlayan bir yapay zekâ sistemi çalışılmıştır. Osteomeatal kompleksi temsil ettiği düşünülen tek bir koronal kesit kullanılmıştır. Toplamda 447 görüntü çalışmaya dâhil edilmiştir. Bunlardan 347'si geliştirilen konvolüsyonel sinir ağını eğitmek için kullanılmıştır. İki kulak burun boğaz uzmanı görüntüleri değerlendirmiştir. Transfer öğrenme yöntemi ile Python'da Inception-V3 mimarisi kullanılmıştır. Sonuçta % 81'lik bir tanı doğruluğu elde edilmiştir (125).

Yapılan bir çalışmada sella tursikanın yapay zekâ ile segmentasyonu ve sınıflandırılması amaçlanmıştır. 199 adet düzleşmiş, 629 adet oval ve 1149 adet yuvarlak şekilli olmak üzere toplamda 1977 adet sagittal KIBT görüntüsü kullanılmıştır. Bu retrospektif çalışmada, KIBT görüntülerinin sagittal kesitlerinde segmentasyon için

U-Net mimarisi, sınıflandırma için GoogleNet Inception V3 mimarisi uygulanmıştır (CranioCatch, Eskişehir, Türkiye). AI modelleri, derin öğrenme modellerine dayalı olarak CBCT görüntülerinde sella tursika segmentasyonu için başarılı sonuçlar elde etmiştir. KIBT görüntülerinin sagittal kesitlerinde sella tursikanın segmentasyonu için duyarlılık, kesinlik ve F-skoru değerleri 1.0, 1.0 ve 1 bulunmuştur (126). İlgili çalışmaya benzer olarak bizim yaptığımız çalışmamızda başka bir önemli anatomik yapı olan TME'nin segmentasyonu ve osteoartrit sınıflaması KIBT görüntüleri üzerinden yine CranioCatch etiketleme programıyla etiketlenmiştir. 2000 adet görüntü kullandığımız çalışmamızda her sınıf için görüntü sayısı eşittir.(500 sağlıklı, 500 düzleşme, 500 erozyon ve 500 osteofit) Ayrıca bizim çalışmamızda hem segmentasyon hem sınıflama için YOLOv5 mimarisi kullanılmıştır. Bizim TME segmentasyonu için elde ettiğimiz duyarlılık, kesinlik ve F1 skoru sırasıyla; 1.0, 0.9953 ve 0.9976'dır. Sınıflama için elde ettiğimiz duyarlılık, kesinlik ve F1 skoru ise; 1.0, 0.7678 ve 0.8686'dır. Sella tursikanın düzleşmiş şekil sınıflandırması için duyarlılık, kesinlik, doğruluk ve F1-skoru sırasıyla 1.0, 0.95, 0.98 ve 0.84; sella tursikanın oval şekil sınıflandırması için sırasıyla 0.95, 0.83, 0.92 ve 0.88; sella tursikanın yuvarlak şekil sınıflandırması için sırasıyla 0.75, 0.94, 0.90 ve 0.83 olarak bulunmuştur (126).

Kronik bel ağrısından sonra, temporomandibular eklem bozuklukları, nüfusun %5 ila 12'sini etkileyen ikinci en yaygın kas-iskelet durumudur ve yıllık sağlık maliyeti 4 milyar dolar olarak tahmin edilmektedir. Temporomandibular eklem osteoartritinde (TMEOA) hastalık yaşla birlikte artar ve asıl amaç morfolojik dejenerasyon ilerlemeden tanı koymaktır. TMEOA'nin kronik hasarını tersine çevirecek tedaviler mevcut olmadığından, erken teşhis, yaygın ve kalıcı eklem hasarını önlemek için en iyi fırsatı sağlayabilir (127).

Yapılan bir çalışmada temporomandibular eklem osteoartritin biyo-belirteçler ve makine öğrenimi kullanarak erken teşhisi amaçlanmaktadır. Yapılan çalışmada temporomandibular eklem osteoartrit durumunu saptamak için makine öğrenimi algoritmalarını kullanarak en alakalı bütünleştirici özellik havuzlarını belirlemek için elli iki değişken (Manyetik rezonans- KIBT görüntüleri, biyomoleküler ve klinik belirteçler) değerlendirilmiştir. Ayrıca dört makine öğrenimi modelinin tanı performansını test edilmiştir: Lojistik Regresyon, Rastgele Orman, LightGBM, XGBoost. Sonuç olarak XGBoost ve LightGBM modelinin doğruluk değeri 0.823, AUC 0.870 ve F1 skoru 0.823 olarak bulunmuştur (127). Bizim çalışmamızda

temporomandibular eklem osteoartriti sınıflaması amaçlanmıştır. Ancak bizim çalışmamız KIBT görüntüleri üzerinden yapılan retrospektif bir çalışmadır. Hastaların klinik muayeneleri, kan ve tükürük değerlendirmesi yapılmamıştır. Ayrıca tek bir modelin (YOLOv5) performansı değerlendirilerek osteoartrit dört sınıfa ayrılmıştır. TME segmentasyonu için bizim elde ettiğimiz doğruluk, AUC ve F1 skorları; 0.9953, 0.9723 ve 0.9976'dır. Osteoartrit sınıflaması için elde ettiğimiz doğruluk ve F1 skoru ise; 0.7678 ve 0.8686'dır.

Başka bir çalışmada temporomandibular eklem rahatsızlığı bulunan ve KIBT'de temporomandibular eklem osteoartriti belirtileri gösteren 314 hastanın görüntüleri üzerinden otomatik olarak temporomandibular eklem osteoartriti teşhisi konulması amaçlanmıştır. Bu hastaların 230'u kadın, 84'ü erkek hastalardan oluşmaktadır. Eklem başına 4 ila 10 görüntü seçilmiştir. Toplamda hastalara ait 3514 adet sagittal KIBT görüntüsü çalışmaya dâhil edilmiştir. Bu çalışmada hastalık tespiti için kullanılan bir nesne algılama modeli olan tek atış algılama (SSD) modelinde eğitim için sadece TMEOA belirtileri gösteren hastaların KIBT görüntüleri dâhil edilmiştir. Eğitim için epoch değeri 10700'dür. Görüntüler üç diş hekimi tarafından değerlendirilmiştir. Görüntüler TMEOA ve TMEOA için belirsiz olmak üzere iki kategoride değerlendirilmiştir. Çalışmadan elde edilen doğruluk, kesinlik, duyarlılık ve F1 skorları sırasıyla; 0.86, 0.85, 0.84 ve 0.84 olarak bulunmuştur. Bu çalışmada sagittal KIBT görüntülerinden TMEOA'nin otomatik tespitinin, derin sinir ağları modeli kullanılarak mümkün olduğu sonucuna varılmıştır (91). Bizim çalışmamızda hasta başına ortalama 4-10 görüntüden oluşan sagittal KIBT görüntüleri üzerinden değerlendirilmiştir, ancak bizim osteoartrit sınıflamamızda bu çalışmanın aksine sağlıklı grupta yer almaktadır. Ayrıca düzleşme, erozyon ve osteofit gibi diğer önemli osteoartrit belirtileri de sınıflamamıza dâhil edilmiştir ve bizim çalışmamızda TME segmentasyonu da yapılmıştır. YOLOv5 modeli ile sınıflandırma için bizim elde ettiğimiz doğruluk, kesinlik, duyarlılık ve F1 skoru ise sırasıyla; 0.7678, 0.7678, 1.0 ve 0.8686'dır.

Temporomandibular eklem osteoartritinin teşhisi için yapılan bir yapay zekâ çalışmasında veri seti konik ışınli bilgisayarlı tomografi görüntülerinden elde edilen üç boyutlu eklem görüntülerinden oluşmaktadır. Eğitim veri seti, 105'i kontrol deneklerinden ve 154'ü TMEOA tanısı almış hastalardan olmak üzere 259 kondilden oluşmaktadır. Görüntü analizi sınıflandırması için, hastalığın belirti ve semptomlarını 5 yıldan daha kısa bir süredir yaşayan 17 hastanın 34 sağ ve sol kondili test veri seti

olarak dâhil edilmiştir. Ayrıca bu çalışmada hastalardan klinik anket, kan ve tükürük örnekleri de toplanmıştır. Temporomandibular eklem üç boyutlu görüntüler üzerinde dejenerasyon seviyelerine göre 5 sınıfa ayrılmıştır. Sınıflandırma ShapeVariationAnalyzer (SVA) olarak adlandırılan bir mimari ile yapılmıştır. Bu çalışmada TME'deki kondil morfolojisindeki 5 aşamalı yapısal dejeneratif değişiklikler için SVA sınıflandırıcısı ve klinisyen arasında % 91 uyum yakalanmıştır (128). Bu çalışmaya benzer şekilde yapılan bir başka çalışmada amaç yine temporomandibular eklem osteoartritinin teşhisi için bir yapay zekâ modeli geliştirmektir. KIBT 'den elde edilen üç boyutlu eklem görüntüleri, hastalardan alınan klinik belirteçler (ağrı, ağız açıklığı gibi), kan ve tükürük örnekleri çalışmaya dâhil edilmiştir. Yine bir önceki çalışmaya benzer olarak TME'in dejenerasyon şiddetine göre üç boyutlu görüntüler üzerinden 5 sınıf belirlenmiştir. Dejenerasyon sınıflandırması ShapeVariationAnalyzer (SVA) ile yapılmıştır. Sonuç olarak ML modelleri kullanılarak temporomandibular eklem osteoartriti 0.823 doğrulukla tahmin edilmiştir (129). Bu çalışmaların aksine bizim çalışmamızda TMEOA teşhis ve sınıflandırması üç boyutlu görüntüler üzerinden değil, yine KIBT 'den elde edilen sagittal kesitler üzerinden yapılmıştır. Osteoartrit teşhisinin üç boyutlu görüntüler üzerinden yapılması konjenital olarak daha küçük ve farklı şekillerde olan sağlıklı eklemler için yanlış teşhise götürebileceği kanısındayız.

Temporomandibular eklem yapay zekâ ile otomatik segmentasyonu amaçlanan bir çalışmada eğitim için yalnızca 40 KIBT görüntüsü kullanılmıştır. Segmentasyon için 3D U-Net modelinden yararlanılmıştır. Sonuç olarak 3D U-Net modeli kullanılan bu çalışmada 0.9760 ortalama zar kat sayısı ile iyi bir performans göstermiştir (130). Bizim çalışmamızda farklı olarak üç boyutlu TME segmentasyonu yapılmamıştır. Biz çalışmamızda segmentasyon için YOLOv5 modelini kullandık ve veri sayımız bu çalışmaya göre daha fazladır. (290 hastaya ait 2000 KIBT görüntüsü) Temporomandibular eklemdaki osteoartritin erken tanısı için temporomandibular eklem otomatik segmentasyonunu amaçlayan başka bir çalışmada 95 hastanın KIBT görüntüleri kullanılmıştır. Bu KIBT görüntüler üzerinden üç boyutlu görüntüler oluşturularak TME'in otomatik segmentasyonu, manuel segmentasyon ile karşılaştırılmıştır. Sonuç olarak elde edilen Dice katsayısı 0.9461 olarak bulunmuştur (standart sapma 0.0888) Bu çalışmadaki tam otomatik kondiler segmentasyon yönteminin, TMEOA'de kondiler dejenerasyonun sınıflandırılmasında doğruluğu önemli ölçüde artıracığı düşünülmektedir. (131).

Çalışmamızda kullandığımız YOLO mimarisi ile yapılan çalışmalara bakacak olursak; insansız hava araçlarının arıza durumunda potansiyel güvenli iniş noktalarını bulmak için yapılan bir çalışmada YOLOv3, YOLOv4 ve YOLOv5l modellerinin performansı karşılaştırılmıştır. Yapılan çalışmanın sonucunda YOLOv5l modelinin biraz daha yavaş çıkarım hızında olmasına rağmen algılama doğruluğu açısından YOLOv3 ve YOLOv4'ten daha iyi performans göstermiştir. YOLOv5l modelinin duyarlılık, kesinlik, F1 skoru ve mAP değerleri sırasıyla; 0.611, 0.707, 0.655 ve 0.633 olarak bulunmuştur (59). Bizde çalışmamızda YOLOv5 modelinin 'x' versiyonunu kullandık. Bu çalışmada model, fotoğraflar üzerinde nesne tespiti (araçlar, yüzme havuzu, tenis kortu gibi) için kullanılırken biz KIBT görüntüleri üzerinde modeli TME segmentasyonu ve osteoartrit sınıflaması yapmak için kullandık

YOLOv4, YOLOv5, YOLOR ve YOLOX modellerinin karşılaştırıldığı başka bir çalışmada veri seti olarak 5078 görüntü kullanılmıştır. Bu çalışmanın amacı sosyal ve kamusal alanlarda güvenliği sağlamak için silah ve bıçak görüntülerinin bilgisayarla otomatik tespitini yapmaktır. YOLO algoritmalarının karşılaştırmalı deneysel çalışmaları yapılmıştır ve sonuç olarak görüntülerde silah ve bıçak tespitinde en başarılı sonuç %97,6 map@0.5 değeri ile YOLOR modelinde elde edilmiştir (58). Bizim çalışmamızda YOLOv5x modelinin TME segmentasyonu için elde ettiği mAP değeri ise %99.5 olarak bulunmuştur. Buradan YOLOv5x modelinin de nesne tespiti için çok iyi bir performans gösterdiği sonucuna varabiliriz.

Manyetik rezonans (MR) görüntüleri üzerinden YOLOv4 algoritması kullanılarak Alzheimer hastalığının tespiti amaçlanan bir çalışmada 464 adet hastalıklı ve 863 adet sağlıklı beyin görüntüsü kullanılmıştır. Sonuç olarak ön işlem adımları uygulanan veri setinde doğruluk değeri 0.67 ve F1 skoru 0.66 olarak bulunmuştur. MR görüntüleri ile yapılan bu çalışmada veri setinde ön işlem adımları uygulanmadan yapıldığında F1 skor 0, doğruluk değeri 0.69 olarak ölçülmüştür. Çalışmadan elde edilen değerler henüz başarılı bir tahmin yeteneği olarak kabul edilemese de ileriki çalışmalarda yol gösterici olacağı sonucuna varılmıştır (132). KIBT görüntülerinde TME'in osteoartrit sınıflandırmasında YOLOv5 modelini kullandığımız çalışmamızda ise doğruluk 0.76 ve F1 skoru 0.86 olarak bulunmuştur.

YOLOv3 modeliyle bitewing radyografiler üzerinde çürük tespiti amaçlanan bir çalışmada hem 4 sınıflı hem 7 sınıflı çürük tespiti yapılmıştır. 994 adet görüntü kullanılan bu çalışmada birleşim üzerinden ortalama kesişme (IoU) hem 0.50 hem 0.75

değerlerinde iken modelin performansı karşılaştırılmıştır. YOLOv3, hem IoU50 hem de IoU75'te kabul edilebilir performanslar vermiştir. 7 sınıflı çürük tespitinde performans ölçütleri düşmesine rağmen, iki eşik karşılaştırılabilir sonuçlar ortaya koymuştur. Ancak model, minenin en dış yüzeyini etkileyen başlangıç aşamasındaki çürükleri tutarlı bir şekilde tespit edememiştir. YOLOv3 modeli dış çürüklerini saptamak ve sınıflandırmak için uygulanabilir bir yöntem olduğu sonucuna varılmıştır (133). Biz çalışmamızda IoU 0.50 olacak şekilde YOLOv5x modeliyle TME osteoartriti için 4 sınıflı bir çalışma yaptık bizimde sonuçlarımız hekimlerin teşhisini kolaylaştırıp, zaman kazandıracak kadar başarılıdır. Bildiğimiz kadarıyla bizim çalışmamız YOLOv5x modeliyle TME segmentasyonu ve TMEOA sınıflaması yapan ilk çalışmadır. Yaptığımız bu çalışma ve elde ettiğimiz sonuçlarla TME osteoartritinin erken teşhisinin mümkün olacağını düşünmekteyiz.

6.SONUÇ VE ÖNERİLER

Yaptığımız çalışmada yapay zekâ modeliyle KIBT görüntüleri üzerinden temporomandibular eklem segmentasyonu ve temporomandibular eklem osteoartrit sınıflandırması sonuçları umut vericidir. Çalışmada eğitilen YOLOv5 modelinin hem temporomandibular eklem segmentasyonu hem de osteoartrit sınıflandırması için elde ettiği F1 değerleri % 86'nın üzerindedir.

Elde edilen sonuçlar yapay zekâ destekli sistemlerin klinik ve radyoloji rutininde hekimlere teşhis için kolaylık ve zaman kazandıracak destek mekanizması olabileceği yönündedir. Temporomandibular eklem osteoartriti gibi toplumda yaygın görülen bir hastalığın teşhisinin kolaylaşması ile hastalığın prognozu daha iyi yönde seyredebilir.

Çalışmamızın dar bir popülasyonda yapılıyor oluşu limitasyonlarımızdan biridir. Yine çeşitli sebeplerle veri setinden çıkarılan hastalar limitasyonlardan biridir. Daha sonra yapılacak buna benzer çalışmalarda daha geniş popülasyonlarda çalışmak yapay zekâ ile daha yararlı bilgiler elde edilmesini sağlayabilir.

Yine çalışmamızın tek KIBT cihazı ve aynı parametrelerle çekilen görüntüler üzerinden yapılmış olması limitasyonlarımızdandır. Farklı cihazlar ve farklı parametrelerle çekilen görüntülerin dâhil edilmesi daha geçerli sonuçlara ulaşılmasını sağlayacaktır.

Çalışmadaki gözlemci sayısının artırılmasıyla ve farklı branşlardan farklı deneyime sahip diş hekimlerinin dâhil edilmesiyle de başarı kıyaslaması daha iyi yapılabilir.

KAYNAKLAR

1. Sağlam H, Tuğba A, Bayrakdar İŞ, Bilgir E, Uğurlu M, Çelik Ö, et al. Diş Hekimliğinde Yapay Zeka: Artificial Intelligence In Dentistry. Sağlık Bilimlerinde Yapay Zeka Dergisi (Journal of Artificial Intelligence in Health Sciences) ISSN: 2757-9646. 2021;1(2):26-33.
2. Doğan ME, Öztürk EMA. Oral Radyolojide Yapay Zeka. HRU International Journal of Dentistry and Oral Research.1(3):78-83.
3. Bilge OM AHM, Dağıstan S, Harorlı A, Yılmaz AB, Çakur B, Çağlayan F, Miloğlu Ö, Sümbüllü MA. Diş Hekimliğinde Muayene ve Oral Diagnoz. Erzurum: Yurtmim Yayıncılık; 2017 2017. 385-420.
4. Alomar X, Medrano J, Cabratosa J, Clavero J, Lorente M, Serra I, et al., editors. Anatomy of the temporomandibular joint. Seminars in Ultrasound, CT and MRI; 2007: Elsevier.
5. Staubesand J, Arıncı K. Sobotta İnsan Anatomisi Atlası. İstanbul: Beta Basın Yayın. 1990;1:301.
6. Ulhuq A. Management of temporomandibular disorders and occlusion. British Dental Journal. 2008;204(9):535.
7. Odabaş B, Arslan SG. Temporomandibular eklem anatomisi ve rahatsızlıkları. Dicle Tıp Dergisi. 2008;35(1):77-85.
8. Yalçın S, Aktaş İ. Dişhekimliğinde Temporomandibular Eklem Hastalarına Yaklaşım. Vestiyer Yayın Grubu İstanbul. 2010.
9. White SC, Pharoah MJ. Oral radiology-E-Book: Principles and interpretation: Elsevier Health Sciences; 2014.
10. Baykal Y. Derin öğrenme ile manyetik rezonans görüntülerde temporomandibular eklem disk deplasmanlarının diagnozu: Sağlık Bilimleri Enstitüsü; 2019.
11. Yıldız NT. Temporomandibular eklem rahatsızlığında farklı tedavi yöntemlerinin çiğneme kas aktivitesi, ağrı, postür, psikolojik durum ve yaşam kalitesi üzerine etkilerinin karşılaştırılması Dr. Fzt. 2021.
12. Gray RJ, Al-Ani Z. Temporomandibular disorders: a problem-based approach: John Wiley & Sons; 2021.
13. Eres N. Kesici rehberliği açısının çiğneme kasları üzerindeki etkisi. 2019.

14. Altun O, Eşer G. Temporomandibular Eklem Kökenli Ağrılar. In: F. Y, editor. Orofasial Ağrı: Tanı ve Güncel Tedavi Yaklaşımları. 1.Baskı. ANKARA: Türkiye Klinikleri; 2021;58-64.
15. Costen JB. I. A syndrome of ear and sinus symptoms dependent upon disturbed function of the temporomandibular joint. *Annals of Otology, Rhinology & Laryngology*. 1934;43(1):1-15.
16. Lavelle ED, Lavelle W, Smith HS. Myofascial trigger points. *Anesthesiology clinics*. 2007;25(4):841-51.
17. Pain Pom. Miyofasiyal Ağrı Sendromu Patofizyolojisinde Son Görüşler.
18. Ahmad M, Schiffman EL. Temporomandibular joint disorders and orofacial pain. *Dental Clinics of North America*. 2016;60(1):105.
19. Eşer G, Duman ŞB, Başaran M, Aşantoğrul F. Manyetik Rezonans Görüntüleme ve Diş Hekimliği. *Black Sea Journal of Health Science*.25-6.
20. Arden N, Nevitt MC. Osteoarthritis: epidemiology. *Best practice & research Clinical rheumatology*. 2006;20(1):3-25.
21. Kiliç SC, Güngörmüş M. Temporomandibular Eklem Osteoartritli Hastalarda Artrosentezi Takiben Yapılan Trombositten Zengin Plazma, Hyaluronik Asit Ve Kortikosteroid Enjeksiyonlarının Temporomandibular Eklem Palpasyonunda Oluşan Ağrıya Etkilerinin Karşılaştırılması. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi*.26(3):407-12.
22. Aydın Ü. Temporomandibular eklem osteoartriti: olgu bildirimi. *Acta Odontologica Turcica*. 2015;32(1):26-30.
23. Ohrbach R. Diagnostic Criteria for Temporomandibular Disorders (DC/TMD) for Clinical and Research Applications: Recommendat. 2014.
24. Koyama J, Nishiyama H, Hayashi T. Follow-up study of condylar bony changes using helical computed tomography in patients with temporomandibular disorder. *Dentomaxillofacial Radiology*. 2007;36(8):472-7.
25. Bhattacharyya I, Chehal H, Gremillion H, Nair M. Gout of the temporomandibular joint. *The Journal of the American Dental Association*. 2010;141(8):979-85.
26. Maini K, Dua A. Temporomandibular joint syndrome. *StatPearls [Internet]: StatPearls Publishing*; 2021.

27. 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).
28. Başaran M, Bozdemir E. Güncel Literatür Işığında Temporomandibular Eklem Rahatsızlıklarında Kullanılan Görüntüleme Yöntemleri. Haliç Üniversitesi Sağlık Bilimleri Dergisi.3(1):15-26.
29. Özkesici MY, Yılmaz S. Oral ve maksillofasiyal radyoloji’de yapay zeka. Sağlık Bilimleri Dergisi.30(3):346-51.
30. Moor J. The Dartmouth College artificial intelligence conference: The next fifty years. Ai Magazine. 2006;27(4):87-.
31. 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. Journal of dental sciences. 2021;16(1):508-22.
32. Aslan E. Yabancı dil öğretiminde robot öğretmenler. Ondokuz Mayıs Üniversitesi Eğitim Fakültesi Dergisi. 2014;33(1):15-26.
33. Tuğçe U. Yapay zeka ve sağlık uygulamaları. İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi.3(1):80-92.
34. Machinery C. Computing machinery and intelligence-AM Turing. Mind. 1950;59(236):433.
35. Shortliffe EH. Computer programs to support clinical decision making. Jama. 1987;258(1):61-6.
36. Best ML, Wade KW. The Internet and Democracy: Global catalyst or democratic dud? Bulletin of science, technology & society. 2009;29(4):255-71.
37. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: past, present and future. Stroke and vascular neurology. 2017;2(4).
38. Hwang J-J, Azernikov S, Efros AA, Yu SX. Learning beyond human expertise with generative models for dental restorations. arXiv preprint arXiv:180400064. 2018.
39. Khanna SS, Dhaimade PA. Artificial intelligence: transforming dentistry today. Indian J Basic Appl Med Res. 2017;6(3):161-7.
40. Samuel AL. Some studies in machine learning using the game of checkers. II—Recent progress. IBM Journal of research and development. 1967;11(6):601-17.

41. Sen D, Chakrabarti R, Chatterjee S, Grewal D, Manrai K. Artificial intelligence and the radiologist: the future in the Armed Forces Medical Services. *BMJ Mil Health*. 2020;166(4):254-6.
42. Tang A, Tam R, Cadrin-Chênevert A, Guest W, Chong J, Barfett J, et al. Canadian Association of Radiologists white paper on artificial intelligence in radiology. *Canadian Association of Radiologists Journal*. 2018;69(2):120-35.
43. Nichols JA, Herbert Chan HW, Baker MA. Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophysical reviews*. 2019;11(1):111-8.
44. Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*. 2018;6(2):25-36.
45. Maltarollo VG, Honório KM, da Silva ABF. Applications of artificial neural networks in chemical problems. *Artificial neural networks-architectures and applications*. 2013:203-23.
46. Öztemel E. *Yapay Sinir Ağları*. İstanbul: Papatya; 2003.
47. Doğan F, Türkoğlu İ. Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*. 2018;1(1):10-21.
48. Coppola Francesca Visser J. What the radiologist should know about artificial intelligence—an ESR white paper. *Insights into imaging*. 2019;10(1):44.
49. Suzuki K. Overview of deep learning in medical imaging. *Radiological physics and technology*. 2017;10(3):257-73.
50. Baydilli YY. Derin öğrenme yöntemleri ile periferik yayma görüntülerinin analizi ve sınıflandırılması. 2020.
51. Şeker A, Diri B, Balık HH. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*. 2017;3(3):47-64.
52. Hwang J-J, Jung Y-H, Cho B-H, Heo M-S. An overview of deep learning in the field of dentistry. *Imaging science in dentistry*. 2019;49(1):1-7.
53. Özkan İ, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*. 2017;6(3):85-104.
54. Koushik J. Understanding convolutional neural networks. *arXiv preprint arXiv:160509081*. 2016.

55. Fırıldak K, Talu MF. Evrişimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi. *Computer Science*. 2019;4(2):88-95.
56. Kırca S. Derin öğrenme yöntemi ile araç ve plaka tanıma: Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü; 2021.
57. Redmon J, Divvala S, Girshick R, Farhadi A, editors. You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 2016.
58. Ağdaş MT, Gülseçen S. Güvenlik Kameralarında Otomatik Silah ve Bıçak Tespit Sistemi: Karşılaştırmalı YOLO Modelleri. *Avrupa Bilim ve Teknoloji Dergisi*. (41):16-22.
59. Nepal U, Eslamiat H. Comparing YOLOv3, YOLOv4 and YOLOv5 for autonomous landing spot detection in faulty UAVs. *Sensors*. 2022;22(2):464.
60. Güçlü E, Aydın İ, Şahbaz K, Erhan A, Karaköse M. Demiryolu bağlantı elemanlarında bulunan kusurların YOLOv4 ve bulanık mantık kullanarak tespiti. *Demiryolu Mühendisliği*. 2021(14):249-62.
61. Wang C-Y, Liao H-YM, Wu Y-H, Chen P-Y, Hsieh J-W, Yeh I-H, editors. CSPNet: A new backbone that can enhance learning capability of CNN. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*; 2020.
62. Murat S. İnsansız hava aracı görüntülerinden derin öğrenme yöntemleriyle nesne tanıma: Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü; 2021.
63. Gers FA, Schmidhuber J, Cummins F. Learning to forget: Continual prediction with LSTM. *Neural computation*. 2000;12(10):2451-71.
64. Gers FA, Schmidhuber J, editors. Recurrent nets that time and count. *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks IJCNN 2000 Neural Computing: New Challenges and Perspectives for the New Millennium*; 2000: IEEE.
65. Yaji A, Prasad S, Pai A. Artificial intelligence in dento-maxillofacial radiology. *Acta Scientific Dental Sciences*. 2019;3(1):116-21.
66. Ronneberger O, Fischer P, Brox T, editors. U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*; 2015: Springer.

67. Minaee S, Boykov YY, Porikli F, Plaza AJ, Kehtarnavaz N, Terzopoulos D. Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*. 2021.
68. Milletari F, Navab N, Ahmadi S-A, editors. V-net: Fully convolutional neural networks for volumetric medical image segmentation. 2016 fourth international conference on 3D vision (3DV); 2016: IEEE.
69. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:14091556*. 2014.
70. Livne M, Rieger J, Aydın OU, Taha AA, Akay EM, Kossen T, et al. A U-Net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease. *Frontiers in neuroscience*. 2019:97.
71. Koç AB, Akgün D. U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması. *Avrupa Bilim ve Teknoloji Dergisi*. 2021(26):407-14.
72. Gündüz G, Cedimoğlu İH. Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini. *Sakarya University Journal of Computer and Information Sciences*. 2019;2(1):9-17.
73. Bektaş M, Yavuz A, Bulut F. Salgın hastalıklarla mücadelede açık kaynak kodlu çözümler. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 2021;3(1):99-105.
74. Muhammed T. Meme Kanseri Histopatolojik Görüntülerinin Konvolüsyonel Sinir Ağları ile Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*. 2019;31(2):391-8.
75. Mol A, van der Stelt PF. Application of digital image analysis in dental radiography for the description of periapical bone lesions: a preliminary study. *IEEE transactions on biomedical engineering*. 1991;38(4):357-9.
76. Kise Y, Ikeda H, Fujii T, Fukuda M, Ariji Y, Fujita H, et al. Preliminary study on the application of deep learning system to diagnosis of Sjögren's syndrome on CT images. *Dentomaxillofacial Radiology*. 2019;48(6):20190019.
77. Orhan K, Yazici G, Kolsuz ME, Kafa N, Bayrakdar IS, Çelik Ö. An Artificial Intelligence Hypothetical Approach for Masseter Muscle Segmentation on Ultrasonography in Patients With Bruxism. *Journal of Advanced Oral Research*. 2021;12(2):206-13.

78. Montúfar J, Romero M, Scougall-Vilchis RJ. Hybrid approach for automatic cephalometric landmark annotation on cone-beam computed tomography volumes. *American Journal of Orthodontics and Dentofacial Orthopedics*. 2018;154(1):140-50.
79. Zhang W, Li J, Li Z-B, Li Z. Predicting postoperative facial swelling following impacted mandibular third molars extraction by using artificial neural networks evaluation. *Scientific reports*. 2018;8(1):1-9.
80. 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):1-9.
81. Srivastava MM, Kumar P, Pradhan L, Varadarajan S. Detection of tooth caries in bitewing radiographs using deep learning. *arXiv preprint arXiv:171107312*. 2017.
82. Lee J-H, Kim D-h, Jeong S-N, Choi S-H. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *Journal of periodontal & implant science*. 2018;48(2):114-23.
83. Kurt Bayrakdar S, Orhan K, Bayrakdar IS, Bilgir E, Ezhov M, Gusarev M, et al. A deep learning approach for dental implant planning in cone-beam computed tomography images. *BMC Medical Imaging*. 2021;21(1):1-9.
84. Lim K, Moles D, Downer M, Speight P. Opportunistic screening for oral cancer and precancer in general dental practice: results of a demonstration study. *British dental journal*. 2003;194(9):497-502.
85. Rosmai MD, Sameemii AK, Basir A, Mazlipahiv IS, Norzaidi M. The use of artificial intelligence to identify people at risk of oral cancer: empirical evidence in Malaysian University. *International Journal of Scientific Research in Education*. 2010;3(1):10-20.
86. De Tobel J, Radesh P, Vandermeulen D, Thevissen PW. An automated technique to stage lower third molar development on panoramic radiographs for age estimation: a pilot study. *The Journal of forensic odonto-stomatology*. 2017;35(2):42.
87. Patil V, Vineetha R, Vatsa S, Shetty DK, Raju A, Naik N, et al. Artificial neural network for gender determination using mandibular morphometric

- parameters: a comparative retrospective study. *Cogent Engineering*. 2020;7(1):1723783.
88. Hasçelik S. Konvolüsyonel sinir ağı kullanılarak trafik işaretlerini gerçek zamanlı bulma ve tanıma: Trakya Üniversitesi, Fen Bilimleri Enstitüsü; 2021.
89. 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;340:250-61.
90. Tokmak M, Kırac A. Evrişimsel Sinir Ağları ile Örümcek Kuşugillerin Bazı Türlerinin Sınıflandırılması. *Bilge International Journal of Science and Technology Research*. 2021;5(1):72-9.
91. Lee K, Kwak H, Oh J, Jha N, Kim Y, Kim W, et al. Automated detection of TMJ osteoarthritis based on artificial intelligence. *Journal of Dental Research*. 2020;99(12):1363-7.
92. Kılıç S. ROC analysis in clinical decision making. *Psychiatry and Behavioral Sciences*. 2013;3(3):135.
93. Pinchi V, Pradella F, Vitale G, Rugo D, Nieri M, Norelli G-A. Comparison of the diagnostic accuracy, sensitivity and specificity of four odontological methods for age evaluation in Italian children at the age threshold of 14 years using ROC curves. *Medicine, Science and the Law*. 2016;56(1):13-8.
94. Davis J, Goadrich M, editors. The relationship between Precision-Recall and ROC curves. *Proceedings of the 23rd international conference on Machine learning*; 2006.
95. Ucuzal H. Yapay zekâya dayalı anlamsal video işleme yöntemlerinin tıpta kullanılabilirliğinin araştırılması: İnönü Üniversitesi Sağlık Bilimleri Enstitüsü; 2020.
96. Heo M-S, Kim J-E, Hwang J-J, Han S-S, Kim J-S, Yi W-J, et al. Artificial intelligence in oral and maxillofacial radiology: what is currently possible? *Dentomaxillofacial Radiology*. 2021;50(3):20200375.
97. Miller DD, Brown EW. Artificial intelligence in medical practice: the question to the answer? *The American journal of medicine*. 2018;131(2):129-33.
98. Khan HA, Haider MA, Ansari HA, Ishaq H, Kiyani A, Sohail K, et al. Automated feature detection in dental periapical radiographs by using deep learning. *Oral surgery, oral medicine, oral pathology and oral radiology*. 2021;131(6):711-20.

99. Lin P, Huang P, Huang P, Hsu H. Alveolar bone-loss area localization in periodontitis radiographs based on threshold segmentation with a hybrid feature fused of intensity and the H-value of fractional Brownian motion model. *Computer methods and programs in biomedicine*. 2015;121(3):117-26.
100. Bouchahma M, Hammouda SB, Kouki S, Alshemali M, Samara K, editors. An automatic dental decay treatment prediction using a deep convolutional neural network on X-ray images. 2019 IEEE/ACS 16th International Conference on Computer Systems and Applications (AICCSA); 2019: IEEE.
101. Wenzel A. Computer-automated caries detection in digital bitewings: consistency of a program and its influence on observer agreement. *Caries research*. 2001;35(1):12-20.
102. Tekin BY. Bitewing ağız içi radyografik görüntülerde derin öğrenme ile diş segmentasyonu 2021.
103. Nagihan K, Özbek Ş. Panoramik Radyografi. *ADO Klinik Bilimler Dergisi*.10(2):75-6.
104. Çelik Ö, Odabaş A, Bayrakdar İŞ, Bilgir E, Akkoca F. Derin öğrenme yöntemi ile panoramik radyografiden diş eksikliklerinin tespiti: Bir yapay zekâ pilot çalışması. *Selcuk Dental Journal*. 2019;6(4):168-72.
105. Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, et al. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology*. 2019;48(4):20180051.
106. Ulama K. Derin öğrenme ile restorasyonların tespit edilerek panoramik dental görüntülerden kimlik tespiti: İstanbul Medeniyet Üniversitesi Lisansüstü Eğitim Enstitüsü Biyolojik Veri ...; 2021.
107. Karaoglu A, Ozcan C, Pekince A, Yasa Y, Tekin BY, Ozdemir D. Artificial intelligence theory and applications. 2021.
108. 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):1-6.
109. Duman S, Yılmaz EF, Eşer G, Çelik Ö, Bayrakdar IS, Bilgir E, et al. Detecting the presence of taurodont teeth on panoramic radiographs using a deep learning-based convolutional neural network algorithm. *Oral Radiology*. 2022:1-8.

110. Cha J-Y, Yoon H-I, Yeo I-S, Huh K-H, Han J-S. Panoptic segmentation on panoramic radiographs: Deep learning-based segmentation of various structures including maxillary sinus and mandibular canal. *Journal of Clinical Medicine*. 2021;10(12):2577.
111. Lee J-S, Adhikari S, Liu L, Jeong H-G, Kim H, Yoon S-J. Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminary study. *Dentomaxillofacial Radiology*. 2019;48(1):20170344.
112. Zhang H, Ong S, Foong K, Dhar T, editors. 3-dimensional orthodontics visualization system with dental study models and orthopantomograms. Third International Conference on Experimental Mechanics and Third Conference of the Asian Committee on Experimental Mechanics; 2005: SPIE.
113. Schiffman E, Ohrbach R, Truelove E, Look J, Anderson G, Goulet J-P, et al. Diagnostic criteria for temporomandibular disorders (DC/TMD) for clinical and research applications: recommendations of the International RDC/TMD Consortium Network and Orofacial Pain Special Interest Group. *Journal of oral & facial pain and headache*. 2014;28(1):6.
114. Jung W, Lee KE, Suh BJ, Seok H, Lee DW. Deep learning for osteoarthritis classification in temporomandibular joint. *Oral Diseases*. 2021.
115. Choi E, Kim D, Lee J-Y, Park H-K. Artificial intelligence in detecting temporomandibular joint osteoarthritis on orthopantomogram. *Scientific Reports*. 2021;11(1):1-7.
116. Kim D-K, Cho B-J, Lee M-J, Kim JH. Prediction of age and sex from paranasal sinus images using a deep learning network. *Medicine*. 2021;100(7).
117. Keser G, Bayrakdar İŞ, Pekiner FN, Çelik Ö, Orhan K. A deep learning algorithm for classification of oral lichen planus lesions from photographic images: A retrospective study. *Journal of Stomatology, Oral and Maxillofacial Surgery*. 2022.
118. Jurczyszyn K, Kozakiewicz M. Differential diagnosis of leukoplakia versus lichen planus of the oral mucosa based on digital texture analysis in intraoral photography. *Advances in Clinical and Experimental Medicine*. 2019;28(11):1469-76.
119. Kim DW, Lee S, Kwon S, Nam W, Cha I-H, Kim HJ. Deep learning-based survival prediction of oral cancer patients. *Scientific reports*. 2019;9(1):1-10.

120. Akarslan Z, Peker İ. Bir diş hekimliği fakültesindeki konik ışınlı bilgisayarlı tomografi incelemesi istenme nedenleri. *Acta Odontologica Turcica*. 2015;32(1):1-6.
121. Orhan K, Bilgir E, Bayrakdar İS, Ezhov M, Gusarev M, Shumilov E. Evaluation of artificial intelligence for detecting impacted third molars on cone-beam computed tomography scans. *Journal of Stomatology, Oral and Maxillofacial Surgery*. 2021;122(4):333-7.
122. Flores A, Rysavy S, Enciso R, Okada K, editors. Non-invasive differential diagnosis of dental periapical lesions in cone-beam CT. 2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro; 2009: IEEE.
123. Abdolali F, Zoroofi RA, Otake Y, Sato Y. Automatic segmentation of maxillofacial cysts in cone beam CT images. *Computers in biology and medicine*. 2016;72:108-19.
124. Rana M, Modrow D, Keuchel J, Chui C, Rana M, Wagner M, et al. Development and evaluation of an automatic tumor segmentation tool: a comparison between automatic, semi-automatic and manual segmentation of mandibular odontogenic cysts and tumors. *Journal of Cranio-Maxillofacial Surgery*. 2015;43(3):355-9.
125. Parmar P, Habib A, Mendis D, Daniel A, Duvnjak M, Ho J, et al. An artificial intelligence algorithm that identifies middle turbinate pneumatization (concha bullosa) on sinus computed tomography scans. *The Journal of Laryngology & Otology*. 2020;134(4):328-31.
126. Duman ŞB, Syed AZ, Celik Ozen D, Bayrakdar İŞ, Salehi HS, Abdelkarim A, et al. Convolutional Neural Network Performance for Sella Turcica Segmentation and Classification Using CBCT Images. *Diagnostics*. 2022;12(9):2244.
127. Bianchi J, de Oliveira Ruellas AC, Gonçalves JR, Paniagua B, Prieto JC, Styner M, et al. Osteoarthritis of the Temporomandibular Joint can be diagnosed earlier using biomarkers and machine learning. *Scientific reports*. 2020;10(1):1-14.
128. Dumast P, Mirabel C, Cevitanes L, Ruellas A, Yatabe M, Ioshida M, et al. A web-based system for neural network based classification in

- temporomandibular joint osteoarthritis. *Computerized Medical Imaging and Graphics*. 2018;67:45-54.
129. Bianchi J, Ruellas A, Prieto JC, Li T, Soroushmehr R, Najarian K, et al., editors. *Decision support systems in temporomandibular joint osteoarthritis: a review of data science and artificial intelligence applications*. *Seminars in Orthodontics*; 2021: Elsevier.
130. Zhang K, Li J, Ma R, Li G, editors. *An end-to-end segmentation network for the temporomandibular joints CBCT image based on 3D U-Net*. 2020 13th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI); 2020: IEEE.
131. Brosset S, Dumont M, Bianchi J, Ruellas A, Cevidanes L, Yatabe M, et al., editors. *3D Auto-Segmentation of Mandibular Condyles*. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC); 2020: Ieee.
132. Aydın S, Taşyürek M, Öztürk C, editors. *MR Görüntüleri Ön İşlenerek Derin Ağlar ile Alzheimer Hastalık Tespiti*. *International Conference On Emerging Sources In Science*; 2022.
133. Panyarak W, Suttapak W, Wantanajittikul K, Charuakkra A, Prapayatatok S. *Assessment of YOLOv3 for caries detection in bitewing radiographs based on the ICCMS™ radiographic scoring system*. *Clinical Oral Investigations*. 2022;1-12.

EKLER

EK-1. Özgeçmiş



EK-2. Etik Kurul Onay Formu

