



T. C.

GAZİANTEP ÜNİVERSİTESİ

DİŞ HEKİMLİĞİ FAKÜLTESİ

**ULTRASONOGRAFİ GÖRÜNTÜLERİNDE DERİN ÖĞRENME
YÖNTEMİYLE SUBMANDİBULAR TÜKÜRÜK BEZLERİNİN
OTOMATİK SEGMENTASYONU VE SONOGRAFİK
PARAMETRELERİN SINIFLANDIRILMASI**

Burak Tunahan ÇİFTÇİ

UZMANLIK TEZİ

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

DANIŞMAN

Dr. Öğr. Üyesi Firdevs AŞANTOĞROL

GAZİANTEP

2024

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlamasından yazıma kadar bütün aşamalarda etik dışı davranışımın olmadığını bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

08/10/2024

Burak Tunahan ÇİFTÇİ



TEŞEKKÜR

Uzmanlık eğitimim ve tez çalışmam boyunca yol gösterici olan, yardımlarını, sabrını ve değerli bilgilerini benimle paylaşan kıymetli hocam ve tez danışmanım Dr. Öğr. Üyesi Firdevs AŞANTOĞROL'a,

Çalıştığımız kısa süre boyunca desteğini ve güler yüzünü esirgemeyen Dr. Öğr. Üyesi Aslıhan ARTAŞ'a,

Uzmanlık eğitimim süresince yanımda olan, destek veren ve bu süreci benimle paylaşan değerli eş kıdemlim Arş. Gör. Mustafa ÖZAYDIN'a ve Uzm. Dt. Besel YILMAZ'a,

Bu süreçte en büyük destekçim, sabırla ve anlayışla her zaman yanımda olan sevgili eşim Dr. Ziyet Sena ÇİFTÇİ'ye,

Akademik yolculuğumda bana her zaman destek olan ve kıymetli bilgilerini benimle paylaşan abim Mehmet Hanifi ÇİFTÇİ'nin şahsında tüm aileme

Sonsuz sevgi, saygı ve teşekkürlerimi sunarım.

İÇİNDEKİLER

KISALTMALAR VE SEMBOLLER	vi
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	xiii
ÖZET	xiv
ABSTRACT.....	xv
1.GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER.....	3
2.1.Tükürük ve Tükürük Bezleri.....	3
2.1.1.Tükürük Bezlerinin Embriyolojisi	4
2.1.2.Majör Tükürük Bezleri	4
2.1.2.2.Majör Tükürük Bezlerinin Anatomisi.....	4
2.1.2.2.1.Parotis Bezi	4
2.1.2.2.2.Submandibular Bez.....	6
2.1.2.2.3.Sublingual Bez	7
2.1.3.Minör Tükürük Bezleri	8
2.2.Tükürük Bezi Görüntüleme Yöntemleri	9
2.2.1.Direkt Radyografi	9
2.2.2.Sialografi.....	10
2.2.3.Manyetik rezonans görüntüleme.....	11
2.2.4.Bilgisayarlı Tomografi.....	12
2.2.5.Sintigrafi	13
2.2.6.18F-FDG pozitron emisyon tomografisi.....	14
2.3.Ultrasonografi	15
2.3.1.Ultrasonografi Fiziği.....	15
2.3.2.Sesin Doku ile Etkileşimi	16
2.3.3.Ultrasonografide Görüntülerin Değerlendirilmesi.....	17
2.3.3.1. Ekojenite	17
2.3.3.2. Akustik Gölge	18
2.3.3.3.Akustik Zenginleşme	19

2.3.4.Ultrasonografide Karşılaşılan Artefaktlar.....	19
2.3.4.1.Reverberasyon Artefaktı	20
2.3.4.2.Kuyruklu Yıldız (Comet Tail) Artefaktı	20
2.3.4.3.Ayna Görüntüsü (Mirror Image) Artefaktı	21
2.3.5.Ultrasonografinin Diş Hekimliğinde Kullanım Alanları	23
2.3.6.Ultrasonografinin Avantajları	24
2.3.7.Ultrasonografinin Dezavantajları.....	24
2.3.8.Tükürük Bezlerinin USG ile Görüntülenmesi	24
2.3.8.1.Parotis Bezinin USG ile Görüntülenmesi	25
2.3.8.2.Submandibular Bezin USG ile Görüntülenmesi	26
2.4.Zekâ ve Yapay Zekâ	27
2.4.1.Makine Öğrenmesi.....	28
2.4.2.Derin Öğrenme	30
2.4.2.1.Özellik Çıkarımı	33
2.4.2.2.Transfer Öğrenme	34
2.4.2.3.Uçtan Uca Öğrenme.....	36
2.4.3.Evrişimli Sinir Ağları (ESA)	37
2.4.3.1.ESA Katmanları	38
2.4.3.1.1. Giriş Katmanı.....	38
2.4.3.1.2. Evrişim Katmanı	39
2.4.3.1.3. Toplu Normalizasyon Katmanı.....	40
2.4.3.1.4. Etkinleştirme (Aktivasyon) katmanı	40
2.4.3.1.5. Havuzlama Katmanı	42
2.4.3.1.6. Tam Bağlantılı Katman.....	43
2.4.3.1.7. DropOut Katmanı	44
2.4.3.1.8. Sınıflandırma Katmanı.....	44
2.4.4. Diş Hekimliğinde Yapay Zekâ	45
2.4.4.1. Restoratif Diş Hekimliğinde Yapay Zekâ.....	45
2.4.4.2. Endodontide Yapay Zekâ.....	46
2.4.4.3. Ortodontide Yapay Zekâ.....	46
2.4.4.4. Ağız, Diş ve Çene Cerrahisinde Yapay Zekâ	46
2.4.4.5. Periodontolojide Yapay Zekâ	47
2.4.4.6. Protetik Diş Hekimliğinde Yapay Zekâ.....	47
2.4.4.7. Çocuk Diş Hekimliğinde Yapay Zekâ	47

2.4.4.8. Ağız, Diş ve Çene Radyolojisinde Yapay Zekâ	48
3. GEREÇ VE YÖNTEM.....	49
3.2. Klinik Muayene.....	49
3.3. Çalışmaya Dahil Edilme ve Dahil Edilmeme Kriterleri.....	50
3.3.1. Çalışmaya dahil edilme kriterleri.....	50
3.3.2. Çalışmaya dahil edilmeme kriterleri	50
3.4. USG Görüntülerinin Alınması ve Submandibular Bez Değerlendirmesi.....	50
3.4.1.Ekojenite Değerlendirmesi	52
3.4.2.Parankim İç Yapısı Değerlendirmesi	53
3.4.3.Marjin Değerlendirmesi	55
3.4.4.Vaskülarizasyon Değerlendirilmesi	57
3.4.5.Vaskülarizasyon Şiddetinin Değerlendirilmesi	59
3.5.Model Geliştirilmesi.....	61
3.6.Submandibular Tükürük Bezi Segmentasyonu	61
3.6.1.Derin Öğrenme Mimarisi.....	61
3.6.1.1.YOLOv8	61
3.6.2.Görüntü Ön İşleme.....	61
3.7.Submandibular Tükürük Bezi Sonografik Parametrelerin Sınıflandırılması	63
3.7.1.Derin Öğrenme Mimarisi.....	63
3.7.1.1.Inception v3	63
3.7.1.2.Xception.....	64
3.7.1.3.VGG (Visual Geometry Group) 16	65
3.7.1.4.VGG 19.....	66
3.7.1.5.MobileNet	67
3.7.1.6.MobileNet v2	68
3.7.2.Görüntü Ön İşleme.....	68
3.7.3. Hiperparametre Ayarlanması	69
3.8.Eğitim Aşaması	70
3.9.Test Aşaması.....	70
3.10.İstatistiksel Analiz.....	70
3.10.1.Karmaşıklık Matrisi Hesaplama Prosedürü	70
3.10.2.Performans Değerlendirilmesi	71

3.10.3.Birleşim üzerinden kesişim (Intersection of Union, IoU).....	72
4.BULGULAR.....	74
4.1. Submandibular Tükürük Bezi Segmentasyonu	74
4.2.Submandibular Tükürük Bezlerinin Sonografik Parametrelerinin	
Sınıflandırılması.....	76
4.2.1.Ekojenite Değerlendirmesi	76
4.2.2.Homojenite Değerlendirmesi	79
4.2.3.Marjin Değerlendirmesi	83
4.2.4.Vaskülarizasyon Değerlendirilmesi	86
4.2.5.Vaskülarizasyon Şiddeti Değerlendirilmesi.....	90
5.TARTIŞMA.....	94
6. SONUÇ VE ÖNERİLER.....	108
7.KAYNAKLAR	109

KISALTMALAR VE SEMBOLLER

18-FDG	18F-Flurodeoksiglukoz
AECG	Amerika-Avrupa Konsensüs Grubu
AUC	Area Under Curve (ROC eğrisinin altında kalan alan)
BT	Bilgisayarlı tomografi
CF	Color flow
DÖ	Derin öğrenme
DP	Doğru pozitif
DVM	Destek vektör makineleri
ESA	Evrişimli sinir ağları
GLCM	Gri Düzey Eş Oluşum Matrisi
GSS	Gougerot-Sjögren Sendromu
IoU	Intersection of Union (Birleşim üzerinden kesişim)
KIBT	Konik ışınlı bilgisayarlı tomografi
KNN	K-En yakın komşuluk
MLP	Multilayer perceptron (Çok katmanlı algılayıcı)
MRG	Manyetik rezonans görüntüleme
MS	Multipl skleroz
MÖ	Makine öğrenmesi
PMA	Pleomorfik adenom
pSS	Primer Sjögren sendromu
PET	Pozitron emisyon tomografisi
ReLU	Rectified Linear Unit (Düzeltilmiş doğrusal birim)
ROC	Receiver Operating Characteristic Curve (Alicı İşlem Karakteristiği)
SSc	Sistemik skleroz
SS	Sjögren sendromu
SWE	Shear wave elastografi
TME	Temporomandibular eklem
USG	Ultrasonografi
VGG	Visual Geometry Group
WT	Warthin tümörü
YN	Yanlış negatif

YP	Yanlış pozitif
YOLO	You Only Look Once (Sadece Bir Kez Bak)
YSA	Yapay sinir ağıları
YZ	Yapay zekâ



ŞEKİLLER LİSTESİ

Şekil 2.1: Parotis bezi ve komşuluğundaki yapılar [32]	5
Şekil 2.2: Fasiyal sinirin çapraz dallarıyla birlikte parotis bezi [32]	6
Şekil 2.3: Submandibular tükürük bezinin komşu anatomik yapılarla ilişkisi [32].....	7
Şekil 2.4: Submandibular ve sublingual tükürük bezlerinin komşu anatomik yapılarla ilişkisi [32]	8
Şekil 2.5: Submandibular ve sublingual tükürük bezlerinin ve submandibular tükürük bezi kanalının komşu anatomik yapılarla ilişkisi [32]	8
Şekil 2.6: Sağ submandibular bezin kanalında büyük bir sialoliti (ok) gösteren panoramik radyografi (kırpılmış) [40].....	10
Şekil 2.7: Parotis (a) ve submandibular (b) bezlerin normal sialogramları [42]	11
Şekil 2.8: Parotis bezinde histolojik olarak kanıtlanmış pleomorfik adenomu olan 55 yaşında bir kadın hastadan alınan aksiyel T2 ağırlıklı MR görüntüsü [47].....	12
Şekil 2.9: Tükürük bezlerinin sınırları bu BT üzerinde beyaz çizgilerle çizilmiştir. A, Parotis bezi; B, submandibular bez [52]	13
Şekil 2.10: SS olan bir hastada (üst) ve normal bir bireyde (alt) tükürük bezi sintigrafisi. Her bir majör tükürük bezi için arka planı düzeltilmiş zaman-aktivite eğrileri gösterilmiştir [39].	14
Şekil 2.11: Sağ parotis bezinde hipermetabolik aktivite gösteren bir kitlenin PET görüntüsü [39].....	15
Şekil 2.12: USG’de dokuların farklı ekojenitelerini gösteren şematik diyagram.....	18
Şekil 2.13: Submandibular bez parankiminde, akustik gölge (oklar) ile hiperekoik doğrusal bir yapı (ok başları) gözlemlenebilir [86].	19
Şekil 2.14: Bir nazolabial kistin posterior akustik zenginleşmesi. Kistin alt sınırı, üst sınırından daha parlak görünmektedir [87].....	19
Şekil 2.15: Bir yenidoğanda palpe edilebilen bir kitle üzerinde elde edilen transvers USG görüntüsünde reverberasyon artefaktı görülmektedir (ok) [90].....	20

Şekil 2.16: Fokal adenomyomatozisli bir hastada, safra kesesinin kalınlaşmış fundusundan kaynaklanan dikey ekoların giderek incelen bir izi olan comet-tail (kuyruklu yıldız) artefaktı (ok işareti) gözlemlenmektedir [92].	21
Şekil 2.17: Sağ hepatik lob seviyesinde elde edilen longitudinal USG görüntüsü, sağ hepatik lobda ekojenik bir lezyon (imleçler) ve akciğer parankiminin öngörülen yerini örten diyaframdan eşit uzaklıkta duplike ekojenik bir lezyon (ok) [90].	22
Şekil 2.18: Kırılma artefaktı. Diyagram (a) ses ışını kırılmasının duplikasyon artefaktına nasıl yol açtığını göstermektedir. (b) üst batin bölgesinin transvers orta hat görüntüsü olup rektus kası refraksiyonuna bağlı olarak aortanın (A) duplikasyonunu göstermektedir [95].	22
Şekil 2.19: Safra kesesi lümenindeki bir lezyonu taklit eden kesit kalınlığı artefaktı [96]	23
Şekil 2.20: Sağlıklı bir parotis tükürük bezinin USG görüntüsü	26
Şekil 2.21: Sol submandibular tükürük bezinin transversal USG görüntüsü	27
Şekil 2.22 : Gerçek verilerle bir MÖ modelinin uygulanması [128]	29
Şekil 2.23: YZ, MÖ ve DÖ'nün tasviri	31
Şekil 2.24: DÖ Modeli ve MÖ ile ilişkisi	32
Şekil 2.25: Görüntülerin iki tarafından özellik çıkarma işleminin bir örneği [153]	34
Şekil 2.26 : A ve B ağlarındaki ilk katmanların aynı olduğu transfer öğrenme yaklaşımının gösterimi [158].	36
Şekil 2.27 : Manuel özellik çıkarma ile karşılaştırmalı olarak uçtan uca öğrenme kavramının gösterimi [161].	37
Şekil 2.28: ESA model mimarisi [165]	38
Şekil 2.29: Evrişim katmanında bir filtre ile birlikte evrişimin nasıl gerçekleştiğini gösteren bir görsel [168]	39
Şekil 2.30 : ReLU aktivasyon fonksiyonu grafiği [173]	41
Şekil 2.31: ReLU aktivasyon fonksiyonuna bir örnek [175]	42
Şekil 2.32: 2×2 filtre boyutu ve 2×2 adım ile maksimum havuzlama ve ortalama havuzlama için örnek [177]	43

Şekil 2.33: Tam bağlantılı katmanın yapısı. [179].....	44
Şekil 2.34: Dropout katmanının şematik diyagramı [181]	44
Şekil 3.1: Çalışmada kullanılan GE LOGIQ S8 with XDclear USG cihazı	50
Şekil 3.2: Submandibular tükürük bezinin USG incelemesinde hasta pozisyonu.	51
Şekil 3.3: Submandibular tükürük bezinin USG incelemesinde probun pozisyonu.	52
Şekil 3.4: USG cihazında B mod (yeşil kare) ve renkli doppler (color flow, CF) (mavi kare) için seçim paneli.	52
Şekil 3.5: Submandibular bez parankiminin ekojenite açısından değerlendirilmesi. A. İzoeoik ekojeniteye sahip submandibular bez, B. Hipoekoik ekojeniteye sahip submandibular bez	53
Şekil 3.6: Submandibular bez parankim iç yapısı açısından değerlendirilmesi. A. Homojen iç yapıya sahip submandibular bez. B. Minimal heterojen iç yapıya sahip submandibular bez. C. Heterojen iç yapıya sahip submandibular bez.	55
Şekil 3.7: Submandibular bezlerin marjinlerinin değerlendirilmesi. A. Düzenli marjine sahip submandibular bez, B. Fokal düzensiz marjine sahip submandibular bez, C. Belirgin düzensiz marjine sahip submandibular bez.	57
Şekil 3.8: Submandibular bezlerin renkli doppler USG ile değerlendirilmesi A: vaskülarizasyon yok B: santral kanlanma C: periferik kanlanma D: santral+periferik kanlanma.....	59
Şekil 3.9: Submandibular bezlerin vaskülarizasyon değerlendirilmesi A: zayıf kanlanma gösteren submandibular bez, B: iyi kanlanma gösteren submandibular bez	60
Şekil 3.10: USG görüntüleri üzerinde submandibular bezlerin poligonal etiketleme işlemi.....	62
Şekil 3.11. Inception V3 modelinin mimarisi [224]	64
Şekil 3.12: Xception DÖ modelinin mimarisi [227].....	65
Şekil 3.13: VGG16 mimarisi [230].....	66
Şekil 3.14: VGG19 mimarisi [232].....	67
Şekil 3.15: MobileNetv2 mimarisi [236].....	68
Şekil 3.16: ROC eğrisi ve eğri altındaki alan AUC grafiği [239].....	72

Şekil 3.17: Birleşim üzerinden kesişim (Intersection of Union, IoU) metriği ölçümü [241].....	73
Şekil 4.1: Submandibular tükürük bezi segmentasyonu için YOLOv8 algoritmasının karmaşıklık matrisi grafiği.....	74
Şekil 4.2: Submandibular tükürük bezi segmentasyonu için YOLOv8 algoritmasının ROC eğrisi ve eğri altındaki alan AUC grafiği.....	75
Şekil 4.3: Submandibular tükürük bezi ekojenite sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: hipoeoik Sınıf 1: izoeoik)	77
Şekil 4.4: Submandibular tükürük bezi ekojenite sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: hipoeoik Sınıf 1: izoeoik)	79
Şekil 4.5: Submandibular tükürük bezi homojenite sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: homojen Sınıf 1: minimal heterojen Sınıf 2: belirgin heterojen).....	81
Şekil 4.6: Submandibular tükürük bezi homojenite sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: homojen Sınıf 1: minimal heterojen Sınıf 2: belirgin heterojen).....	82
Şekil 4.7: Submandibular tükürük bezi marjin sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: düzenli Sınıf 1: fokal düzensiz Sınıf 2: belirgin düzensiz).....	84
Şekil 4.8: Submandibular tükürük bezi marjin sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: düzenli Sınıf 1: fokal düzensiz Sınıf 2: belirgin düzensiz).....	86

Şekil 4.9: Submandibular tükürük bezi vaskülarizasyon sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: kanlanma yok Sınıf 1: santral kanlanma Sınıf 2: periferel kanlanma Sınıf 3: santral+periferel kanlanma)... 88

Şekil 4.10: Submandibular tükürük bezi vaskülarizasyon sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: kanlanma yok Sınıf 1: santral kanlanma Sınıf 2: periferel kanlanma Sınıf 3: santral+periferel kanlanma)... 89

Şekil 4.11: Submandibular tükürük bezi vaskülarizasyon şiddeti sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: yetersiz kanlanma Sınıf 1: iyi kanlanma)..... 91

Şekil 4.12: Submandibular tükürük bezi vaskülarizasyon şiddeti sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: yetersiz kanlanma Sınıf 1: iyi kanlanma)..... 93

TABLÖLAR LİSTESİ

Tablo 4.1: Submandibular tükürük bezi segmentasyonu için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri	75
Tablo 4.2: Submandibular tükürük bezi ekojenite sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri	79
Tablo 4.3: Submandibular tükürük bezi homojenite sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri	82
Tablo 4.4: Submandibular tükürük bezi marjın sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri	86
Tablo 4.5: Submandibular tükürük bezi vaskülarizasyon sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri.....	89
Tablo 4.6: Submandibular tükürük bezi vaskülarizasyon şiddeti sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri	93

ÖZET

ULTRASONOGRAFİ GÖRÜNTÜLERİNDE DERİN ÖĞRENME YÖNTEMİYLE SUBMANDİBULAR TÜKÜRÜK BEZLERİNİN OTOMATİK SEGMENTASYONU VE SONOGRAFİK PARAMETRELERİN SINIFLANDIRILMASI

Burak Tunahan ÇİFTÇİ

Uzmanlık Tezi, Ağız, Diş ve Çene Radyolojisi Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Firdevs AŞANTOĞROL

Ekim 2024, Sayfa 123

Tükürük bezleri, vücudun ağız içi homeostazını sağlamakta önemli rol oynayan ekzokrin salgı bezleridir. Tükürük bezlerinin temel görevi, oral ve genel sağlık için kritik olan tükürüğü üretmek ve salgılamaktır. Bazı hastalıklar ve klinik durumlar, tükürük bezlerinin B-mod ve renkli Doppler ultrasonografi (USG) görüntülerinde belirgin değişikliklere neden olabilir. Bu değişiklikler, tükürük bezlerinin parankim yapısında bozulmalar, ekojenite değişiklikleri, bezin sınırlarında düzensizlikler ve vaskülarizasyon değişiklikleri olarak kendini gösterebilir. Bu çalışmanın amacı, submandibular tükürük bezlerinin USG görüntülerini derin öğrenme (DÖ) yöntemleriyle otomatik olarak segmente etmek ve bu görüntülerdeki sonografik parametreleri sınıflandırmaktır. Gaziantep Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı'na başvuran 18 yaş ve üzeri toplam 312 bireyin sağ ve sol submandibular tükürük bezleri USG ile görüntülendi. Bu görüntülerde YOLOv8 DÖ algoritmasının submandibular tükürük bezlerini segmente etme başarısı ve VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 DÖ algoritmalarının sınıflandırma performansı değerlendirildi. Model performanslarını değerlendirmek için karmaşıklık matrisi kullanıldı. Submandibular tükürük bezi segmentasyonunda %100 doğruluk gösteren YOLOv8 modeli, ekojenite değerlendirmesinde %97.6 doğrulukla en başarılı sonuçları verdi. Homojenite sınıflandırmasında en yüksek doğruluk %93.6 ile MobileNetv2, marjin değerlendirmesinde ise en yüksek doğruluk %74.4 ile MobileNet tarafından elde edildi. Vaskülarizasyon şiddeti ve lokalizasyon değerlendirmelerinde ise YOLOv8 modeli sırasıyla %100 ve %89.3 doğruluk oranlarıyla en başarılı sonuçları sağladı. Sonuç olarak, bu çalışma, submandibular tükürük bezlerinin USG görüntülerinde DÖ algoritmalarının yüksek segmentasyon ve sınıflandırma başarısını ortaya koymuştur. Bu bulgular, klinik uygulamalarda karar destek sistemlerinin geliştirilmesi ve klinisyenlere tanı süreçlerinde önemli bir destek sağlanması açısından umut vericidir.

Anahtar sözcükler: tükürük bezleri, submandibular bez, ultrasonografi, derin öğrenme, yapay zekâ

ABSTRACT

THE AUTOMATIC SEGMENTATION OF SUBMANDIBULAR SALIVARY GLANDS AND CLASSIFICATION OF SONOGRAPHIC PARAMETERS USING DEEP LEARNING METHODS IN ULTRASOUND IMAGES

Burak Tunahan ÇİFTÇİ

Specialization Thesis, Department of Oral and Maxillofacial Radiology

Supervisor: Assistant Professor Firdevs AŞANTOĞROL

October 2024, Pages 123

Salivary glands are exocrine glands that play a crucial role in maintaining oral homeostasis. Their primary function is the production and secretion of saliva, which is essential for both oral and general health. Certain diseases and clinical conditions can cause significant changes in the B-mode and color Doppler ultrasonography (USG) images of salivary glands, including alterations in parenchymal structure, echogenicity, glandular margins, and vascularization. The aim of this study was to automatically segment submandibular salivary glands in USG images using deep learning (DL) methods and classify the sonographic parameters. A total of 312 individuals aged 18 and older who applied to the Department of Oral and Maxillofacial Radiology at Gaziantep University Faculty of Dentistry underwent USG imaging of their right and left submandibular salivary glands. The segmentation performance of the YOLOv8 DL algorithm and the classification accuracy of VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2, and YOLOv8 were evaluated. A confusion matrix was used to evaluate model performances. YOLOv8 achieved 100% accuracy in submandibular gland segmentation and 97.6% accuracy in echogenicity assessment. MobileNetv2 achieved the highest accuracy in homogeneity classification (93.6%), while MobileNet showed the best performance in margin evaluation (74.4%). YOLOv8 also performed best in assessing vascularization intensity (100%) and localization (89.3%). In conclusion, this study demonstrates the high segmentation and classification performance of DL algorithms in USG images of submandibular salivary glands. These findings are promising for developing decision support systems in clinical practice, offering significant support to clinicians during diagnosis.

Keywords: salivary glands, submandibular gland, ultrasonography, deep learning, artificial intelligence

1.GİRİŞ VE AMAÇ

Tükürük bezleri, vücudun ağız içi homeostazının sağlanmasında önemli bir rol oynayan ekzokrin salgı bezleridir. Tükürük bezlerinin ana işlevi, oral ve genel sağlık için kritik olan tükürük üretimini ve salgılamasını yapmaktır. Tükürük, sindirimin ilk aşamasında kayganlaştırıcı olarak görev yaparken, antimikrobiyal özellikler taşır ve diş mineralizasyonunu destekler (1). Submandibular tükürük bezleri, toplam tükürük salgısının büyük bir bölümünün üretiminden sorumludur ve bu bezlerde meydana gelen bozukluklar, bireyin yaşam kalitesini ciddi şekilde etkileyebilir (2). Tükürük bezlerindeki patolojik durumlar; sialolitler, enfeksiyonlar, kist ve tümörler, Sjögren sendromu (SS) gibi otoimmün hastalıklar gibi geniş bir yelpazede ortaya çıkabilir. Ayrıca, vücuttaki birçok sistemik hastalığın da tükürük bezlerini etkilediği bilinmektedir (3).

1980’li yıllardan bu yana tükürük bezlerinin incelenmesinde kullanılan en yaygın yöntemlerden biri ultrasonografidir (USG) (4). Son derece etkili, invaziv olmayan ve uygulanması kolay olan tükürük bezi USG’si, tükürük bezi anomalilerini değerlendirmede uzmanlar arasında giderek daha popüler hale gelmiştir (5).

Çeşitli hastalıklar ve klinik durumlar, tükürük bezlerinin B-mod ve renkli doppler USG görüntülerinde belirgin değişikliklere yol açabilir. Bu değişiklikler, tükürük bezlerinde parankim iç yapısında bozulmalar, ekojenite değişiklikleri, bezin sınırlarında bozulmalar ve vasküler yapılarında değişiklikler olarak kendini gösterebilir (6). Özellikle B-mod USG, tükürük bezlerinin morfolojik yapısını detaylı bir şekilde değerlendirirken, renkli Doppler USG vasküler yapıları ve bezin kanlanma durumu hakkında bilgi sağlar (7). Bu bulguların değerlendirilmesi ve hastalığın ilerleme aşamalarının belirlenmesi amacıyla, çeşitli sınıflandırma sistemleri geliştirilmiştir (6, 8, 9). Bu sınıflandırma sistemleri, tükürük bezlerindeki patolojik değişiklikleri farklı evrelere ayırarak, hastalığın ne kadar ilerlemiş olduğunu ve hangi aşamada olduğunu objektif kriterlerle belirler. Bu nedenle, USG bulgularının standardize edilmiş bir sınıflandırma sistemi ile değerlendirilmesi hem hastalığın tanısı hem de tedavi sürecinin takibi açısından büyük önem taşır. Doğru ve tutarlı bir değerlendirme, hastalığın erken teşhisine katkı sağlayarak, uygun tedavi planının zamanında uygulanmasını mümkün kılar (10).

Ancak bu görüntülerin manuel olarak analiz edilmesi zaman alıcıdır ve uzmanlık gerektiren bir süreçtir (11). Deneyimli bir gözlemci, USG görüntülerindeki farkları değerlendirebilir ve doğru bir teşhis koyabilir. Ancak bu süreç, insan faktörüne bağlı olarak bazı hatalara açık olabilir ve değerlendirme sürecinin uzunluğu nedeniyle tanı süreçlerini geciktirebilir (12).

Yapay zekâ (YZ), bilgisayar algoritmalarının insan zekasına benzer şekilde problem çözme veya bilgi edinme yeteneğini ifade eder. YZ'nin bir alt alanı olan makine öğrenimi (MÖ), toplanan verilerden öğrenmeyi ve kurallar türeterek yeni veriler hakkında çıkarım ve tahmin yapmayı amaçlar (13). Diğer MÖ türlerinde olduğu gibi, veri kalitesine ve uzmanlığa oldukça bağımlı olan yaklaşımların aksine, MÖ'nün ana dallarından biri olan derin öğrenme (DÖ), büyük miktarda ham veriden önemli özellikleri otomatik olarak çıkarır ve görüntü sınıflandırma, hedef tespiti ve görüntü segmentasyonu gibi alanlarda son derece etkilidir. Son yıllarda özellikle tıbbi görüntüleme alanında da popülerlik kazanmıştır (14). DÖ algoritmaları, sınırlı eğitim örneklerinden temel özellikleri çıkararak yüksek performanslı tahminler yapmak için çok sayıda gizli katmana sahip olan bir evrişimli sinir ağlarını (ESA) kullanır (15).

YZ, USG işlemlerinde büyük bir potansiyele sahiptir (16). Aynı zamanda deneyimsiz kullanıcıların eğitim sürelerini kısaltır, klinik iş akışında kalite güvencesini artırır ve tıbbi kaynakların daha verimli bir şekilde kullanılmasına katkıda bulunur (16). Bu sayede hem klinik etkinlik artırılmakta hem de sağlık hizmetlerinde verimlilik sağlanmaktadır. Ayrıca YZ, insan hatası riskini en aza indirirken hasta bakımının ve tedavi sonuçlarının kalitesini iyileştirme potansiyeline sahiptir (17).

Bu çalışmanın amacı, submandibular tükürük bezlerinin USG görüntülerini DÖ yöntemleriyle otomatik olarak segmente etmek ve bu görüntülerdeki sonografik parametreleri sınıflandırmaktır.

2. GENEL BİLGİLER

2.1. Tükürük ve Tükürük Bezleri

Tükürük sıvısı yaklaşık olarak %99'u sudan oluşan, çeşitli elektrolitler (sodyum, potasyum, kalsiyum, klorür, magnezyum, bikarbonat, fosfat), enzimler, immünoglobulinler ve diğer antimikrobiyal faktörler, mukozal glikoproteinler, albümin kalıntıları ve ağız sağlığı için önemli bazı polipeptitler ve oligopeptitler gibi proteinler içeren ekzokrin bir salgıdır (18, 19). Ayrıca glikoz, üre ve amonyak gibi azotlu ürünler de bulundurmaktadır (20). Bu bileşenler etkileşim halindedir ve tükürüğe atfedilen çeşitli işlevlerden sorumludur (19). Total tükürük, tükürük bezlerinden, diş eti oluşu sıvısından, ağız mukozası transüdasından, oral bakterilerden, gıda kalıntılarından, epitel ve kan hücrelerinden, ayrıca ilaçlar veya kimyasal ürünlerin kalıntılarından gelen sıvıların çok bileşenli bir karışımını ifade eder (20-24). İstirahat halindeyken, eksojen veya farmakolojik uyarım olmaksızın, ağız dokularını örten, nemlendiren ve kayganlaştıran bir film şeklinde uyarılmamış salgı olarak adlandırılan az ama sürekli bir tükürük akışı mevcuttur. Uyarılmış tükürük ise bazı mekanik, tat, koku veya farmakolojik uyarılar karşısında üretilir ve günlük tükürük üretiminin yaklaşık %80 ila %90'ına katkıda bulunur (25, 26).

Üç majör tükürük bezi olan parotis, submandibular ve sublingual bezler ile ağız boyunca dağılmış olan minör tükürük bezleri, ağız içi tükürük üretimine katkıda bulunur. Majör tükürük bezleri, ağızdaki tükürük olarak bilinen ve çeşitli bileşenlerden oluşan bu sıvının yüzde 90'ına; minör tükürük bezleri ise kalan yüzde 10'una katkıda bulunur. Normal günlük tükürük üretimi 0.5 ila 1.5 litre arasındadır. Submandibular bezler istirahat halindeki (uyarılmamış) tükürüğe, parotis bezleri ise uyarılmış tükürüğe en büyük katkıyı sağlar. Sublingual bezlerin uyarılmamış ve uyarılmış tüm tükürüğe katkısı düşüktür (27, 28). Minör tükürük bezleri tüm tükürük hacmine büyük katkıda bulunmasalar da müköz salgıları nedeniyle oral mukozanın kayganlaştırılmasında ve korunmasında önemli rol oynarlar. Parotis bezi salgısı tamamen serözdür, submandibular ve sublingual bez salgıları ise karışıktır (müköz ve seröz). Asiner hücreler tarafından oluşturulan birincil tükürük, plazmaninkine benzer bir iyonik bileşime sahiptir. Duktal hücreler tarafından sodyum ve klorürün geri emilimi ile hipotonik bir solüsyona modifiye edilir. Tükürük salgısı çeşitli uyarıcılar tarafından artırılabilir. Tükürük akışı uyarının niteliğine, süresine ve yoğunluğuna bağlıdır. Güçlü

asidik uyaran, yüksek frekanslı çiğneme ve yüksek ısırma kuvveti tükürük çıkışının artmasına neden olur. Parasempatik stimülasyon seröz tükürük salgısının artmasına neden olurken, sempatik stimülasyon müköz tükürük salgılarına neden olur (29).

2.1.1.Tükürük Bezlerinin Embriyolojisi

Majör ve minör tükürük bezleri, ağız mukozası epitelinden gelişir. Bu bezlerin oluşumu, altıncı ve yedinci gebelik haftalarında, Notch sinyal yolunun etkisiyle ilkel ağız boşluğundan çıkan solid epitelyal tomurcuklar şeklinde başlar. Bu tomurcuklar, golf sopasını andıran bir şekil alarak alttaki mezenkime doğru büyür. Tükürük bezinin bağ dokusu, nöral krest hücrelerinden kaynak alır ve bezdeki tüm parankimal doku, ağız epitelinin çoğalmasıyla meydana gelir. Parotis bezi, altıncı haftanın başlarında belirginleşir ve ağız ektoderminden kaynaklanan epitelyal hücre tomurcuklarından gelişir. Gelişim sürecinde, epitel kordonları kanalize olarak lümen oluşturur ve bu kanallar yaklaşık onuncu haftada netleşir. Yuvarlaklaşan kordon bölümleri asinuslara farklılaşır ve tükürük salgısı yaklaşık on sekizinci haftada başlar. Bezin kapsülü ve bağ dokusu çevre mezenkimden gelişir. Submandibular tükürük bezi ise altıncı haftanın sonlarına doğru belirginleşir ve stomedial tabanındaki endodermal epitel tomurcuklarından oluşur. Dilin yan kısımlarında gelişen katı hücresel uzantılar geriye doğru büyüyüp daha sonra dallanarak farklılaşır. Asinuslar on ikinci haftada gelişmeye başlarken, tükürük salgısı on altıncı haftada başlar. Submandibular bezin büyümesi, doğumdan sonra müköz asinusların oluşumuyla devam eder. Dilin yan kısmında çizgisel bir yarık oluşur ve ductus submandibularis'in oluşumu için bu yarığın kenarları birleşir. Sublingual tükürük bezi ise diğer bezlerden yaklaşık iki hafta sonra, sekizinci haftada belirginleşir. Sulcus paralingualis bölgesinde çok sayıda endodermal epitelyal tomurcuktan gelişen bu bez, dallanarak kanalize olur ve ağız tabanına açılan 10-12 bağımsız kanalı oluşturur. Ayrıca majör tükürük bezlerine ek olarak, intraoral mukoza epitelinden köken alan çok sayıda minör tükürük bezi de mevcuttur ve bu bezler, intrauterin üçüncü ayda gelişimini tamamlar (30, 31).


2.1.2.Majör Tükürük Bezleri

2.1.2.2.Majör Tükürük Bezlerinin Anatomisi

2.1.2.2.1.Parotis Bezi

Parotis bezi, çift taraflı olarak konumlanmış olup tükürük bezlerinin en büyüğüdür ve sternokleidomastoid kas ile masseter kası arasında sıkışmıştır, mandibulanın ramusunu kaplar ve bu yapılardan arkaya ve öne doğru taşar. Ters piramit şeklindeki bu bez, boynun derin fasyasındaki bir yarık içinde yer alır. Antero-inferiorda, bu fasya parotisi submandibular tükürük bezinden ayırır ve stylomandibular ligament olarak adlandırılan bağı oluşturur. Parotis lenf düğümleri parotis fasyasının hem üzerinde hem de derininde yer alır. Bezin çok sayıda yapı ile ilişkisi vardır (Şekil 2.1 ve 2.2). Bunlar;


- Süperiorunda dış kulak yolu bulunur.
- İnferiorda digastrik kasın arka karnı üzerinde uzanır.
- Anteriorda üzerindeki masseter kas ile mandibular ramustan taşar.
- Medialde, stiloid çıkıntı ve buna bağlı kaslarla birlikte yer alır; bu yapılar bezi, internal karotid arter, internal jugular ven, son dört kranial sinir ve farenksin yan duvarından ayırır. (32-35).



Şekil 2.1: Parotis bezi ve komşuluğundaki yapılar (32)

Parotis kanalı (Stenon kanalı) (Şekil 2.1) bezin ön tarafından çıkar, masseter üzerinden ilerler ve buccinator'u delerek ikinci üst azı dişi hizasında ağız içinde açılır. Kanal, zigomatik arkın biraz altında gergin masseter üzerinde kıvrılabilir. Fasiyal sinir (Şekil 2.2 ve 2.3) parotis bezinin içinden geçmesi bakımından benzersizdir. Ayrıca, fasiyal sinirin parotis bezinin yüzeyel ve derin lobları arasında önemli bir sınır oluşturduğunu

belirtmek de önemlidir. Bu ayrım, cerrahi müdahaleler açısından kritik bir rol oynar ve bezin farklı bölümlerine erişimi etkiler (36). Daha sonra sinir, kafatasının stilomastoid forameninden çıkar ve stiloid çıkıntının lateraline doğru kıvrılır (32).




Şekil 2.2: Fasiyal sinirin çapraz dallarıyla birlikte parotis bezi (32)

2.1.2.2.2.Submandibular Bez

Sağda ve solda, lingual ve sublingual bölgelerin altında, mandibula korpusu ile digastrik kasın ön ve arka karnı arasında yer alan submandibular üçgenin orta ve arka kısmında konumlanmış olan submandibular bez, badem şeklinde olup önden arkaya ve yukarıdan aşağıya oblik bir şekilde uzanır. Bu bez, mylohyoid kasın arka sınırı etrafında birleşen büyük bir yüzeysel lob ve küçük bir derin lobdan oluşur. Yüzeysel lob çene angulusunda, boynun derin fasyasının bir cebi içinde, mandibula ile mylohyoid kas arasında sıkışmış ve bu kasın üzerine binmiş olarak uzanır. Posteriora, stylomandibular ligamentin kalınlaşmasıyla ayrılan parotise temas eder. Yüzeysel olarak bez platizma ile kaplıdır ve fasiyal ven ile platizma kasını innerve eden fasiyal sinirin (VII) servikal dalı tarafından çaprazlanır. Derin tarafında, bez çoğunlukla mylohyoid kas üzerinde konumlanır, ancak posteriora hyoglossus kas üzerinde uzanır ve burada hem lingual sinir (V) hem de hipoglossal sinir (XII) ile temas eder, çünkü bunlar dile doğru ilerlerken bu kas üzerinde uzanırlar. Fasiyal arter beze arkadan yaklaşır, üzerinde kavis çizer ve oluklar açar, üst tarafı mandibulanın alt kenarına ulaşır ve yüz üzerinde masseterin önünde yükselir. Bezin medial yönünden derin kısmı hyoglossus kas boyunca uzanır. Submandibular kanal (Wharton kanalı) bezin bu derin kısmından (Şekil 2.4 ve 2.5) dilin lateral tarafı


boyunca ağız tabanı mukozasının altından çıkarak frenulum linguae'nin hemen lateral tarafına açılır (32, 33, 37).




Şekil 2.3: Submandibular tükürük bezinin komşu anatomik yapılarla ilişkisi (32)

2.1.2.2.3. Sublingual Bez

Badem şeklindeki bu bez (Şekil 2.1 ve 2.5) ağız tabanında submandibular bezin derin kısmının hemen önünde submukozal olarak uzanır. Medialde dil tabanından submandibular kanal ve lingual sinir ile ayrılırken, lateralde mandibulanın medial yüzündeki sublingual fossa ile ilişkilidir. Doğrudan ağız tabanına ve ayrıca submandibular kanala giren bir dizi kısa kanalla (Bartholin kanalları) drene olur (32).



Şekil 2.4: Submandibular ve sublingual tükürük bezlerinin komşu anatomik yapılarla ilişkisi (32)



Şekil 2.5: Submandibular ve sublingual tükürük bezlerinin ve submandibular tükürük bezi kanalının komşu anatomik yapılarla ilişkisi (32)


2.1.3.Minör Tükürük Bezleri

Minör tükürük bezleri ağız boşluğunun önemli bileşenleridir, oral mukozada özellikle bukkal mukoza, labial mukoza, lingual mukoza, yumuşak/sert damak ve ağız tabanı boyunca yoğunlaşmış 800 ila 1000 küçük tükürük bezinden oluşur ve salgıları doğrudan dokuları ıslatır. Bağımsız bezler genellikle submukozada veya kas lifleri arasında bulunur ve mukoza asiner hücreleri ile seröz veya seromüköz demilün hücrelerinden meydana gelen salgı uçları gruplarından oluşur. Duktal sistemler interkale kanallar, genellikle bazal çizgileri olmayan intralobüler kanallar ve doğrudan mukozaya açılan boşaltım kanallarından oluşur. Minör tükürük bezleri, doku kayganlaştırma ve bakteriyel agregasyonda aktif olan yüksek glikozillenmiş müsinler salgılar. Ayrıca çeşitli antimikrobiyal proteinler ve inummoglobulinler salgılarlar ve lingual seröz (von Ebner's) bezler sindirim enzimleri ve olası tat algılama işlevleri olan proteinler salgılarlar. Majör ve minör tükürük bezleri arasında olduğu gibi minör bezler arasında da muköz ve seröz salgı ürünlerinin doğası ve bileşimi açısından önemli farklılıklar vardır. Bazı minör bezler daha çok muköz, bazıları ise seröz salgı üretir (38).

2.2.Tükürük Bezi Görüntüleme Yöntemleri

2.2.1.Direkt Radyografi


Direkt radyografi, tükürük bezlerindeki sialolitleri incelemenin ucuz ve basit bir yoludur (Şekil 2.6). Duktal sialolitlerin yaklaşık beşte biri radyolusent olduğundan, bu görüntüleme prosedürü günümüzde tükürük bezi görüntülemesinde sınırlı bir kullanıma sahiptir. Ayrıca, flebolitler, kalsifikasyonlu hemanjiomlar veya kalsifiye lenf nodları direkt radyografide sialolitleri taklit edebilir. Parotis bezleri ve Stenon kanalında lokalize olan silolitleri izlemek için panoramik radyografiler ve anteroposterior projeksiyon, submandibular bezindeki görüntülemek için ise panoramik radyografiler, oklüzal grafiler, anteroposterior ve lateral oblik projeksiyonlar kullanılabilir (39).



Şekil 2.6: Sağ submandibular bezin kanalında büyük bir sialoliti (ok) gösteren panoramik radyografi (kırpılmış) (40).

2.2.2.Sialografi

Konvansiyonel X-ray sialografi 20. yüzyılın başlarından itibaren tanı aracı olarak kullanılan eski bir tekniktir (41) (Şekil 2.7). Daha sonraları konik ışınlı bilgisayarlı tomografi (KİBT) ve bilgisayarlı tomografi (BT) ile kullanılmaya başlanmıştır. Bu sialografi teknikleri, yağda çözünen radyoopak bir kontrast madde verildikten sonra ilgili tükürük bezi kanallarının ve bu kanallarda bir daralma olup olmadığının gösterilmesini sağlar. Sialolit varlığı olmadan kontrast maddenin düzensiz birikimi ve duktal obstrüksiyon malignitenin dolaylı belirtileri olabilir. Sialografi ile ilişkili potansiyel komplikasyonlar arasında duktal sistemin hasar görmesi, klinik olarak kronik enfeksiyonun akutlaşması ve kontrast maddeye karşı alerjik reaksiyonlar yer alır. Bu görüntüleme yöntemi akut sialoadenit vakalarında ve iyot içeren kontrast maddeye karşı daha önce alerjik reaksiyon gösteren vakalarda kontrendikedir (39).




Şekil 2.7: Parotis (a) ve submandibular (b) bezlerin normal sialogramları (42)

2.2.3. Manyetik rezonans görüntüleme

Manyetik rezonans görüntüleme (MRG), özellikle neoplastik hastalıklar olmak üzere başlıca tükürük bezi hastalıklarının değerlendirilmesinde önemlidir. Güçlü bir malignite şüphesi varsa, MRG tercih edilen yöntemdir (43). Tümör 3 cm'den büyükse veya parotis bezinin derin lobunda bulunuyorsa, USG'nin lezyonları yeterince görüntüleme ve tanımlama konusunda yetersiz kalabileceği durumlarda MRG tercih edilmelidir. MRG'nin kullanılmadığı durumlarda ise BT alternatif bir inceleme yöntemi olarak kullanılabilir. MRG submandibular, sublingual ve parotis bezindeki tükürük bezi tümörlerinin boyutunu tanımlamada yardımcı olur. Kafa tabanı tutulumu da MRG ile genellikle net bir şekilde görülür (44). Büyük bir malign tümör ve kraniyal sinir hasarı durumunda, lezyonun lokal boyutunu değerlendirmek ve perinöral tümör yayılımını ve intrakraniyal invazyonu tespit etmek için MRG kullanılmalıdır (43, 45). MRG'nin dezavantajları, genelde incelemenin gerçekleştirildiği cihazın manyetik alan gücüne ve tekniğin kendisinin getirdiği kısıtlamalara bağlıdır. Bu kısıtlamalar, özellikle kalp pili, nörostimülatör veya infüzyon pompası gibi cihazlar taşıyan hastalar için önemli riskler doğurur. Bu cihazlar, güçlü manyetik alan etkisiyle işlevini yitirebilir ve hastanın

yaşamını tehdit edebilecek durumlar ortaya çıkabilir. Benzer şekilde, manyetik alan ve radyo frekansı dalgalarına maruz kalan sabit metal protezlere veya anevrizma klipslerine sahip hastalarda, bu materyallerin ısınma, yer değiştirme veya yumuşak dokularda yanıklara neden olma riski bulunmaktadır. Bu nedenle, bu tür olgularda MRG uygulaması kontrendikedir. Ayrıca, kapalı alan korkusu (klostrofobi) olan hastalar için de MRG incelemeleri zorluk yaratabilmektedir (46).




Şekil 2.8: Parotis bezinde histolojik olarak kanıtlanmış pleomorfik adenomu olan 55 yaşında bir kadın hastadan alınan aksiyel T2 ağırlıklı MR görüntüsü (47)

2.2.4.Bilgisayarlı Tomografi

Tükürük bezlerinin bilgisayarlı tomografisi (Şekil 2.9), MRG'ye kıyasla kolay, hızlı ve ucuzdur (48), ancak baş ve boyunda iyonize radyasyona maruz kalmayı gerektirir. Kontrastlı BT için, böbrek fonksiyon bozukluğu ve kontrast maddeye karşı önceden geçirilmiş ciddi alerjik reaksiyon gibi yalnızca birkaç kontrendikasyon vardır. Ağız içerisindeki metalik restorasyonlardan kaynaklanan artefaktlar genellikle tanısal zorluklara neden olur (49). Kontrastsız BT sialolit, yumuşak doku kalsifikasyonu, malign lezyonlar ve kemik erozyonlarını gösterebilir. Genellikle parotis bezinin atenüasyonu, daha yüksek yağ içeriği nedeniyle submandibular bezden biraz daha düşüktür. Konik ışınlı BT, konvansiyonel BT'ye göre daha düşük radyasyon dozu ile kemik, sialolitiazis ve sialografide kontrast madde gibi yüksek yoğunluklu yapıların nispeten yüksek uzaysal çözünürlüğünü sağlar (50, 51). Kontrastlı BT, akut vakalarda,

MRG'nin kontrendike olduđu durumlarda veya MRG'ye eriřimin sınırlı olduđu durumlarda yararlıdır (39).




řekil 2.9: Tükürük bezlerinin sınırları bu BT üzerinde beyaz çizgilerle çizilmiştir. A, Parotis bezi; B, submandibular bez (52)

2.2.5.Sintigrafi

Bu görüntüleme yöntemi SS'de oral tutulumun varlığını ve kapsamını incelemek için (řekil 2.10) uygulanabilir, ayrıca cerrahi tedavi, radyasyon tedavisi ve radyoiyot tedavisi sonrası takip amaçlı da kullanılmaktadır. Tükürük bezi sintigrafisi, radyasyon tedavisini takiben tükürük bezi fonksiyonunun öngörülmesinde de yardımcı olabilir (53). Sintigrafi sonuçları SS hastalarında tükürük bezlerinin klinik ve histopatolojik özellikleriyle korelasyon göstermektedir (54-59). Akut sialoadenitte (bakteriyel veya viral kaynaklı), hiperemi ve intralober kanalları sıkıřtıran ödem nedeniyle radyonüklid alımında artış (hiperaktivite) görülür. Sintigrafi benign ve malign tümörler arasında ayırım yapmak için kullanılamaz ve cerrahi bir prosedürün sonucunu öngöremez.

$^{99m}\text{TcO}_4^-$ (perteknetat iyonu), vücutta klor iyonuna benzer şekilde dağılım gösterir. Tükürük bezi sintigrafisinde kullanılan sodyum perteknetat ($\text{Na}^{99m}\text{TcO}_4$) bileşiği, bu özelliği sayesinde tükürük bezlerinin fonksiyonel değerlendirilmesinde kullanılır (39).




Şekil 2.10: SS olan bir hastada (üst) ve normal bir bireyde (alt) tükürük bezi sintigrafisi. Her bir majör tükürük bezi için arka planı düzeltilmiş zaman-aktivite eğrileri gösterilmiştir (39).

2.2.6.18F-FDG pozitron emisyon tomografisi

18F-Fluorodeoksiglukoz (^{18}F -FDG) pozitron emisyon tomografisi (PET), metabolik aktiviteye sahip hücrelerde bu glukoz analogunun alımına dayanır ve kesin bir anatomik lokalizasyon için BT ile birleştirilir (Şekil 2.11). ^{18}F -FDG, tükürük bezi tümörlerinde GLUT 1'in aşırı eksprese edildiği spesifik taşıyıcılar, GLUT 1 ve GLUT 5 tarafından alınır, ancak PET, iyi huylu ve kötü huylu tükürük bezi tümörlerini yeterli kesinlikte ayırt edemez (60). Birincil tanı aracı olarak klinik kullanımı sınırlıdır, ancak malign

tükürük bezi tümörlerinin evrelendirilmesinde potansiyel bir değere sahip olabilir (61, 62).



Şekil 2.11: Sağ parotis bezinde hipermetabolik aktivite gösteren bir kitlenin PET görüntüsü (39)

2.3.Ultrasonografi

USG, iyonize radyasyon içermeyen, yüksek frekansta ses dalgalarının kullanıldığı, yumuşak dokuların görüntülenmesinde sıkça tercih edilen, invaziv olmayan, ekonomik, kolay erişilebilir, basit ve güvenilir bir görüntüleme yöntemidir (63). USG, tıp alanında karın, meme, karaciğer, dalak, böbrek ve diğer yüzeysel yumuşak doku lezyonlarının patolojilerinin tespitinde önemli bir teşhis aracı olarak başarıyla kullanılmaktadır (64). Yapılan çalışmalar USG'nin tükürük bezi patolojileri, maksillofasiyal bölgeyi tutan kist ve tümörler gibi yumuşak doku lezyonlarının tanısında da başarıyla kullanılabileceğini göstermiştir (65, 66). Ayrıca maksillofasiyal bölgedeki yüzeysel fasiyal boşluk enfeksiyonlarının boyutunu değerlendirmek için de kullanılmıştır (67, 68). US frekansı 2 ila 20 MHz arasındadır; Çoğu durumda yüzeysel yapıların görüntülenmesi için yüksek frekanslı dönüştürücüler (10-15 MHz aralığına kadar) ve derindeki yapıların görüntülenmesi için ise düşük frekanslı dönüştürücüler (tipik olarak 2-5 MHz) kullanılır (69).

2.3.1.Ultrasonografi Fiziği

USG, diğer radyolojik görüntüleme yöntemlerinden farklı olarak noniyonize ses dalgalarını kullanır. Ses enerjisi, ortamdaki moleküler titreşimin bir dalga halinde

yayılmasıyla meydana gelen mekanik bir enerjidir. Sesin frekansı, moleküllerin saniyedeki titreşim sayısı ile ölçülür. 1 hertz (Hz), sesin saniyede bir titreşimini ifade eder [1 MHz = 1.000.000 Hz (megahertz)]. Radyolojide kullanılan ses frekansı genellikle 2-12 MHz arasında değişir (63).

Bu görüntüleme yöntemi Curie kardeşlerin 1880 yılında keşfettiği piezoelektrik (basınç-elektrik) etkisinden faydalanır. Piezoelektrik olayda, kuartz gibi kristallere elektrik enerjisi uygulandığında bu kristaller genişleyip daralarak şekil değiştirir. Bu şekilde, elektrik enerjisi ses enerjisine dönüştürülür ve gelen ses dalgaları benzer bir şekilde elektrik enerjisine çevrilir. Enerji dönüştürücü maddeler transdüser olarak adlandırılırken, transdüseri taşıyan başlık ise prob olarak adlandırılır (70). En yaygın kullanılan piezoelektrik malzeme kurşun zirkonattır (71, 72). Sesin oluşturulması ve dokuya iletilmesi ile dokudan yansıyan seslerin algılanması ve elektrik sinyaline dönüştürülmesi, prob tarafından gerçekleştirilir. Transdüser, vücudun incelenecek bölgesine yüksek frekanslı ses dalgalarını (ultrases) yayarak işlev görür. USG, görüntü alıcının (prob) ve enerjinin (ultrases) vücut dışında aynı tarafta olduğu bir uygulamadır. Bu süreç "refleksiyon" olarak adlandırılır (73).

2.3.2.Sesin Doku ile Etkileşimi

Ultrasonik dalgalar vücut içinde farklı dokulara ulaştığında, enerji kaybıyla sonuçlanan çeşitli değişikliklere yol açarlar. Bu değişiklikler arasında yansıma, saçılma, kırılma ve absorpsiyon yer alır (74).

Akustik empedans, bir maddenin ultrasonik dalgalarla etkileşimindeki direnci ifade eder ve dokunun yoğunluğu ile sesin hızı arasındaki ilişkiyi belirler (63, 75). Farklı akustik empedansa sahip ses dalgaları, ara yüzeylerden geçerken yansıma olarak adlandırılan değişikliklere uğrarlar. Bu yansıma, incelenen dokulardaki akustik empedans farkıyla doğru orantılıdır. Ses dalgalarının farklı yönlerde dağılması, *saçılma* olarak adlandırılırken, ses dalgalarının doğrultusunu değiştirmesi *kırılma* olarak tanımlanır. Ses dalgalarının bir ortamda ilerlerken meydana gelen kayıpların toplamı *absorpsiyon* olarak bilinir (63, 76). Ses dalgaları, farklı akustik dirence sahip ara yüzeylerden geçerken *yansıma* yapar. Yansımanın miktarı, dokular arasındaki akustik direnç farklarına bağlıdır. Bu fark ne kadar büyükse, yansıma ve saçılma da o kadar belirgindir. Yansıma, yumuşak dokular içinde nispeten azken, yumuşak doku-hava veya yumuşak doku-kemik arasında daha fazladır (63).

Ultrason incelemelerinde, deriye iyi bir akustik temas sağlamak için jel gibi bir madde kullanılır. Yapı derinse düşük frekanslı, yüzeysel ise yüksek frekanslı prob kullanılması önerilir (74).


USG, dört görüntüleme moduna sahiptir (77):

- Amplitüd modu (A mod): Vücutta bir çizgiyi tarayan ve ekoların grafiksel olarak ekranda gösterildiği basit bir moddur (78).
- Parlaklık modu (B mod): Dokulara gönderilen ses dalgaları ve gelen ekolarla bir düzlemi gösteren, gri tonlamalı, iki boyutlu görüntüler oluşturur. Ses dalgasının gönderilmesi ve yansması arasındaki süre ile dönen dalgaın yansıma miktarı hesaplanır ve farklı gri tonlarıyla kodlanır (79).
- Hareket modu (M mod): B modunun seçili bir hattı izleyerek tek bir eksen boyunca yayılan bir ışınla tüm dokuların hareketi hakkında veri sağlayan bir moddur (80). Bu mod diş hekimliğinde dil hareketlerinin ve yutkunma paternlerinin incelenmesi gibi dinamik görüntüleme gerektiren alanlarda kullanılır. Özellikle ortodontik tedavilerde, yutma sırasında dilin işlevsel analizini yapmak için tercih edilir. Bunun yanı sıra, temporomandibular eklem (TME) hareketlerinin izlenmesi ve fonksiyonel bozuklukların teşhisinde de önemli bir rol oynar (81, 82).
- Doppler modu: Kan akımının ölçülmesi ve görüntülenmesini Doppler etkisi aracılığıyla sağlayan bir moddur (78).

2.3.3.Ultrasonografide Görüntülerin Değerlendirilmesi

2.3.3.1. Ekojenite


Dokuların mekanik özelliklerindeki farklılıklar nedeniyle ses dalgalarının farklı yansımaları sonucu ultrason görüntüleri oluşur (Şekil 2.12). Geriye dönen eko seviyesinin genliği ekojenite olarak tanımlanır ve yansımanın büyüklüğüyle doğru orantılıdır. Sıvılar ses dalgalarını yansıtmadığı için, sıvı dolu oluşumlar sinyal üretmez ve bu nedenle anekoik olarak görünürler. Hipoekoik alanlar az yansıma ve zayıf sinyal üreten alanları gösterirken, hiperekoik alanlar çok fazla yansıma ve yoğun sinyal üreten alanları ifade eder. Ses dalgalarının proba eşit ulaştığı alanlara ise izoekoik alanlar denir, yani karşılaştırılan dokularla aynı ekojeniteye sahip alanlar olarak tanımlanırlar (63, 83).



Şekil 2.12: USG’de dokuların farklı ekojenitelerini gösteren şematik diyagram

2.3.3.2. Akustik Gölge


Akustik gölge, bir yüzeyin ardına sesin geçmemesi veya çok az geçmesi nedeniyle oluşan ve sesin soğurulması veya yansımaları sonucu ortaya çıkan, anekoik veya hipoekoik olarak görülen alandır. Akustik gölgenin oluşması için, yansıtan yüzeyin boyutunun ses demetinin büyük bir kısmını engelleyecek kadar büyük olması gerekir. Daha küçük yapılar, arkasına yeterli miktarda sesin geçmesine izin verir ve bu durumda akustik gölge oluşmaz. Hiperekojen yapılar (örneğin kemik, sialolit ve yumuşak doku kalsifikasyonları), ses dalgalarını büyük ölçüde yansıtarak arka bölgelerinin hipoekoik veya anekoik olarak görünmesine neden olur. Akustik gölge, sadece kalsifiye yapıların sesi soğurmasından değil, aynı zamanda yumuşak doku ile kalsifiye yapı arasında ses dalgasının büyük bir kısmının yansımalarından da kaynaklanır. Başka bir gölgeleme şekli ise kist kenarlarının arkasında görülen ve kenar gölgesi veya kırılma gölgesi olarak adlandırılan şekildir. Yüksek derecede atenuasyon oluşturan yumuşak dokuların arkasında bazen kısmi gölgelenme görülebilir. Bu durum genellikle yağ içeren ve yumuşak doku ile çevrili kitlelerin arkasında görülür (63, 84, 85).



Şekil 2.13: Submandibular bez parankiminde, akustik gölge (oklar) ile hiperekoik doğrusal bir yapı (ok başları) gözlemlenebilir (86).

2.3.3.3.Akustik Zenginleşme

Arka duvar zenginleşmesi olarak da bilinen, akustik gölgelenmenin tam tersi bir fenomen olan akustik zenginleşme, komşu dokulardan daha sıvı olan yapıların ses dalgalarını daha az absorbe etmesinden kaynaklanır. Kistik yapıların derinliklerinde bulunan dokular daha fazla sesi yansıtır ve bu yapıların arka kısımları, aynı derinlikteki çevre yapılarla karşılaştırıldığında daha parlak bir görüntü oluşturur. İçi ekojenik materyalle dolu olan nekrotik tümörler, pürülan sıvılar, kan gibi sıvı yapılar, arkalarındaki akustik zenginleşmeyle ayırt edilir. Bu görünüm, kistik ve solid yapıların birbirinden ayırt edilmesinde önemlidir. Ancak komşu solid dokudan daha az ses emen solid kitlelerin de bir miktar eko birikimi oluşturabilecekleri gözden kaçırılmamalıdır (63, 84, 85).




Şekil 2.14: Bir nazolabial kistin posterior akustik zenginleşmesi. Kistin alt sınırı, üst sınırından daha parlak görünmektedir (87).

2.3.4.Ultrasonografide Karşılaşılan Artefaktlar

2.3.4.1.Reverberasyon Artefaktı

Reverberasyon artefaktı, bir yansıtıcı yüzeyden gelen ses dalgasının bir kısmının prob yüzeyinden geri dönüp tekrar yansıtıcı yüzeye çarpması sonucunda oluşan bir fenomendir. Bu durumda, yansıtıcı yüzeyin arkasında daha zayıf bir yansıma meydana gelir. Bu artefakt, incelenen yapının transdüserle yakın bölümünde çoklu çizgilenmeler şeklinde görünür ve kistik yapıların doğru bir şekilde incelenmesini engeller. Bu sorunu azaltmak için transdüser ile kistik yapı arasındaki mesafe artırılabilir (84, 85, 88, 89).



Şekil 2.15: Bir yenidoğanda palpe edilebilen bir kitle üzerinde elde edilen transvers USG görüntüsünde reverberasyon artefaktı görülmektedir (ok) (90).

2.3.4.2.Kuyruklu Yıldız (Comet Tail) Artefaktı


Kuyruklu yıldız artefaktı, bir tür reverberasyon artefaktıdır ve sesin iki yansıtıcı yüzey arasında gidip gelmesi sonucunda oluşur. Yansıtıcı yüzeyin arkasında düzenli aralıklarla yerleşmiş ve giderek solan paralel çizgiler şeklinde görülen bu artefakt, V şeklinde veya Ring Down (Zil Çalma) artefaktı olarak da bilinir (84, 88, 91).



Şekil 2.16: Fokal adenomyomatozisli bir hastada, safra kesesinin kalınlaşmış fundusundan kaynaklanan dikey ekoların giderek incelen bir izi olan comet-tail (kuyruklu yıldız) artefaktı (ok işareti) gözlemlenmektedir (92).

2.3.4.3.Ayna Görüntüsü (Mirror Image) Artefaktı


Ses, ışığın bir aynadan yansımaları gibi düzgün yüzeylerden yansır. Düz yüzeylerde oluşan artefaktta, nesne ile hayali görüntüsü aynı şekil ve boyutta olurken, eğik yüzeylerde ayna artefaktında hayali görüntüde distorsiyon meydana gelir. Gaz, ses dalgalarını tamamen yansıtmaları nedeniyle vücuttaki en iyi akustik aynadır. Örneğin, trakea boyunun incelenmesinde, içerisindeki hava nedeniyle güçlü bir yansıtıcı yüzey oluşturur (84, 88, 91).



Şekil 2.17: Sağ hepatic lob seviyesinde elde edilen longitudinal USG görüntüsü, sağ hepatic lobda ekojenik bir lezyon (imleçler) ve akciğer parankiminin öngörülen yerini örten diyaframdan eşit uzaklıkta duplike ekojenik bir lezyon (ok) (90)

2.3.4.4.Refraksiyon (Kırılma) Artefaktı

Sesin farklı yayılım hızına sahip olduğu iki ortam arasında geçerken yayılım yönünde değişiklik olması durumuna refraksiyon denir. Bu artefakt, objelerin konumunu değiştirerek yanıltıcı kopyalar oluşturabilir. Ses hızı, yağ dokusunda en az ve yumuşak dokularda en fazla olduğundan, refraksiyon artefaktları en belirgin olarak yağ-yumuşak doku ara yüzlerinde görülür (74, 85, 93, 94).



Şekil 2.18: Kırılma artefaktı. Diyagram (a) ses ışını kırılmasının duplikasyon artefaktına nasıl yol açtığını göstermektedir. (b) üst batin bölgesinin transvers orta hat görüntüsü olup rektus kası refraksiyonuna bağlı olarak aortanın (A) duplikasyonunu göstermektedir (95).

2.3.4.5.Kesit Kalınlığı Artefaktı

USG sırasında, görüntü alanı dahilinde ve dışında olmak üzere iki ayrı kesit kalınlığı bulunur. Sesin kesit kalınlığı boyutu, incelenen bölgedeki kistik oluşumun genişliğinden daha büyük olduğunda, kistin dışındaki yapıların ekoları, kistik yapının ekojenitesinin artmasına neden olabilir. Bu durum, basit bir kistin kompleks bir kist olarak yanlış değerlendirilmesine yol açabilir (84, 85).



Şekil 2.19: Safra kesesi lümenindeki bir lezyonu taklit eden kesit kalınlığı artefaktı (96)

2.3.5. Ultrasonografinin Diş Hekimliğinde Kullanım Alanları

- ✓ Major tükürük bezlerinden parotis ve submandibular tükürük bezlerinin süperpozisyonlu incelenmesi,
- ✓ Tükürük bezinin akut iltihaplanmaları, kistleri, tümörleri ve tükürük bezi taşlarının tanımlanması,
- ✓ Baş ve boyun bölgesindeki şişliklerin ve lenf nodlarının değerlendirilmesi,
- ✓ Sjögren sendromunun teşhis edilmesi,
- ✓ Dil lezyonlarının incelenmesi,
- ✓ Postoperatif hematoma ve ödemlerin değerlendirilmesi,
- ✓ Diş kaynaklı apselerin ve selülitlerin değerlendirilmesi,
- ✓ Distraksiyon osteogenezisi uygulanan hastalarda distraksiyon bölgesinin incelenmesi,
- ✓ Diş kırıklarının veya çatlaklarının tespiti,
- ✓ Yumuşak doku lezyonlarının incelenmesi,
- ✓ Dişin kök ucu lezyonlarının tespiti ve değerlendirilmesi,
- ✓ Kist, tümör gibi kemik içi anormalliklerin değerlendirilmesi,
- ✓ Çene ve yüz kemiği kırıklarının değerlendirilmesi,
- ✓ Aftöz ülserlerin değerlendirilmesi
- ✓ Periodontal kemik kaybının değerlendirilmesi,
- ✓ Diş eti ve çene kaslarının kalınlığının ölçümü,

- ✓ Temporomandibular eklem hastalıklarının değerlendirilmesi amaçları ile USG kullanılır (4, 97-101).

2.3.6.Ultrasonografinin Avantajları

- ✓ Dinamik ve kolay kullanılabilir bir tekniktir.
- ✓ İnvaziv olmayan bir tekniktir.
- ✓ Özellikle yüzeysel yapıların incelenmesinde faydalıdır.
- ✓ Yaygın olarak bulunur ve nispeten ucuzdur.
- ✓ Hasta tarafından iyi tolere edilir.
- ✓ Ekipmanlar taşınabilir.
- ✓ Artefaktlar azdır.
- ✓ Ağır ekipmanlar olmadan inceleme sağlanabilir.
- ✓ Bilinen kümülatif biyolojik etkileri yoktur.
- ✓ Normal fonksiyona müdahale etmez.
- ✓ Tekrarlanabilir ve basit olduğu kanıtlanmıştır.
- ✓ Kolay erişilebilir ve ağrısızdır.
- ✓ Gözlemci eğitildikten sonra elde edilen görüntülerin okunması kolaydır.
- ✓ Hızlıdır ve muayenesi hasta başında bile yapılabilir.
- ✓ Gerçek zamanlı görüntüleme imkânı vardır (101).

2.3.7.Ultrasonografinin Dezavantajları

- ✓ Tekniğin operatöre ve ekipmana bağlı olması dezavantajları arasındadır.
- ✓ Klinik olarak, ultrason frekansları nedeniyle tüm korteks veya spongiöz kemik değil, sadece kemik yüzeyleri görüntülenebilir.
- ✓ TME incelenmesi, kondil başının lateral bölümü ve temporal kemiğin zigomatik prosesi tarafından ses dalgalarının emilmesi ve derin yapıların, özellikle diskin sınırlı erişilebilirliği nedeniyle zordur.
- ✓ Standart tekrarlanabilir taramalarda elde edilen BT ve MR görüntülerinin aksine, arşivlendiğinde USG görüntülerinin yönlendirmesi ve yorumlanması zor olabilir.
- ✓ Ultrason görüntüleri, transdüser geri dönen sinyale eşlik eden ve yorumlamayı zorlaştıran doğal gürültüden etkilenir.
- ✓ Deneyimli araştırmacılar tarafından gerçekleştirilmelidir (101).

2.3.8.Tükürük Bezlerinin USG ile Görüntülenmesi

USG, tükürük bezlerinin hacmi, boyutu ve parankimal yapısı gibi morfolojik özelliklerini ve komşu anatomik yapılarla ilişkilerini detaylı olarak ortaya koyar (102). Submandibular ve sublingual tükürük bezlerinin tamamı ile parotis bezinin yüzeysel bölümünün değerlendirilmesine imkân tanır (102-104). Parotis bezi derin bölümü, mandibular ramusun akustik gölgesi nedeniyle ultrasonla tam olarak incelenemez (102, 104, 105).

Hasta, tüm ultrason muayenelerinde olduğu gibi rahat olmalı ve boyun bölgesi açık olmalıdır. Hasta sırt üstü yatar pozisyonda ve baş hafif şekilde geriye doğru konumlandırılmış olmalıdır. Boynun aşırı gerilmesini gerektiren muayeneler için küçük bir yastık kullanılabilir (106).

Bugünün ultrason cihazlarında genellikle 5-12 MHz geniş bantlı lineer probalar kullanılır. 10 MHz üzerindeki prob frekansları, özellikle tükürük bezlerinin yapısının değerlendirilmesinde faydalı olabilir. Bezlerin derin kısımlarında bulunan büyük tümörler ve lezyonların değerlendirilmesinde ise 5-10 MHz prob kullanılır (105). Ancak, bu durum bazen diagnostik bir ikileme yol açabilir. Frekansın artması, daha yüksek çözünürlük sağlasa da muayene edilebilen doku derinliğinin azalmasına neden olabilir. Bu nedenle, değişken frekanslı bir prob, hem derin hem de yüzeysel dokuların aynı seansta değerlendirilmesini sağlar (106).

Genel bir kural olarak, ultrason muayenesi sırasında herhangi bir anatomik bölge veya lezyon, en az iki farklı ultrason penceresi kullanılarak değerlendirilmelidir (105, 106). Lenf nodlarının değerlendirilmesi ve eşlik eden veya ilişkili hastalıkların araştırılması için boynun tamamında tarama yapılmalıdır (105).


Herhangi bir ultrason muayenesinin önemli bir bileşeni Doppler ultrason görüntülemeleridir (106). Fokal lezyonların kanlanması değerlendirilmesi, lezyonun benign/malign veya inflamatuvar/non-inflamatuvar olup olmadığını belirlemek için bu adım son derece önemlidir (106, 107).

2.3.8.1.Parotis Bezinin USG ile Görüntülenmesi

Sonografik olarak parotis bezi, homojen, ince, yoğun ekolarla oluşmuş, çevredeki parotis boşluğunun sınırlarını oluşturan yapılardan daha yüksek ekojenitede görünmektedir. Bez içindeki normal, genişlememiş kanallar, yüksek frekanslı transdüserler, su yastığı veya jel ped kullanılsa bile ultrasonografik olarak

görüntülenemez. Genişlemiş Stenon kanalı, 10 MHz üzerinde yüksek frekanslı bir transdüserle, boru şeklinde veya tek bir ekojenik çizgi olarak gözlemlenebilir (108, 109).


Parotis tükürük bezini yüzeyel ve derin olarak ayıran fasiyal sinir genellikle rutin olarak USG ile görüntülenemez. Bu nedenle, eksternal karotit arterin lateralinde uzanan retromandibular ven, bezin derin ve yüzeyel lobunu ayırt etmek için kullanılabilir. Bez içindeki damarların yerleşimi sabittir ve bu damarların ultrasonda tespit edilmesi, fokal lezyonların bölgeselleştirilmesinde önemlidir (108-110).



Şekil 2.20: Sağlıklı bir parotis tükürük bezinin USG görüntüsü

2.3.8.2.Submandibular Bezin USG ile Görüntülenmesi

Submandibular bezin tamamı sonografik olarak görülebilir. İç yapısı parotis bezine benzerdir. Genişlememiş kanallar nadiren sonografik olarak görüntülenebilir. Tükürük bezi kanalları, limon gibi asitli gıdalarla uyarıldıktan sonra daha belirgin hale gelebilirler. Kanallar, renkli doppler USG ile lingual damarlardan ayrılabilirler (37, 109).



Şekil 2.21: Sol submandibular tükürük bezinin transversal USG görüntüsü

2.4.Zekâ ve Yapay Zekâ


Zeka, öğrenme yeteneği, anlama ve mantık ile akıl yürütme temelinde kararlar veya bakış açıları oluşturma kapasitesi olarak tanımlanır (111). İnsanların, hızlı karar vermelerini ve hayatta kalmak için gerekli sofistike araçları yaratmalarını sağlayan en yüksek zekâ seviyesine sahip oldukları söylenmektedir. Temelde, düşünme ve akıl yürütme, insanlar ile hayvanlar arasındaki en belirgin fark olarak kabul edilir. Binlerce yıldır, insanlar çevrelerine karşı meraklı kalmış, sayısız deney yapmış ve yeni fikirler geliştirmiştir. Bilgisayar bilimleri ve mühendislikteki ilerlemeler, İkinci Dünya Savaşı'ndan hemen sonra 1950'lerde ortaya çıkan ve tarihteki en devrimsel kavramlardan biri olmaya aday olan YZ kavramının başlangıcını getirmiştir (112). McCarthy, 1955'te yayımlanan makalesinde YZ'yi şu şekilde tanımlamıştır: "Zeki makineler, özellikle zeki bilgisayar programları yapma bilimi ve mühendisliğidir." (113). 1970'lerde matematikçi Richard Bellman ise YZ kavramını; öğrenme, karar verme, problem çözme ve insan benzeri düşünce üretebilme yeteneklerinin otomatik olarak gerçekleştirilebilmesi olarak tanımlamıştır (114). YZ birçok farklı tanıma sahip olduğundan, bir tanesine bağlı kalmak zor olabilir.

YZ kendisine son yıllarda birçok dalda kullanım alanı bulmuştur. Bunlar arasında YZ destekli dijital asistanlar (115), hava tahmini (116), otonom araçlar (117), oyun endüstrisi (118), mühendislik iş çizelgeleme sistemleri (119), dolandırıcılık tespit ve önleme sistemleri (120), ticaret ve kaynak kullanımı (121) ve sağlık (122) alanları bulunmaktadır.

2.4.1.Makine Öğrenmesi

MÖ, bilgisayarların veri örneklerinden öğrenmesini ve verilere dayalı tahminler veya kararlar almasını sağlayan algoritmaların ve modellerin geliştirilmesine odaklanan bir teknolojidir (123). Geleneksel programlama yaklaşımları, sorunların çözümü için sabit kodlanmış kurallara dayanırken, MÖ sistemleri büyük miktarda örnek veri ile bir görev ve bu görevin nasıl gerçekleştirileceğine dair kullanılacak kalıpların belirlenmesine odaklanır. Sistem, istenen çıktıya en iyi şekilde nasıl ulaşılacağını veri örnekleri üzerinden öğrenir (124). MÖ, YZ'nin öğrenme yönünü temsil ederek, veri kümelerini en iyi şekilde temsil eden algoritmalar geliştirir (125). Artan veri erişimi, MÖ sistemlerinin geniş bir örnek havuzunda eğitilmesine olanak tanırken, bilgisayarların artan işlem gücü bu sistemlerin analitik yeteneklerini destekler (126). MÖ günümüzde çeşitli sektörlerde uygulanmakta olup, uygulama alanları giderek artmaktadır. Nesneleri tanıma, konuşmayı metne dönüştürme, kullanıcı ilgi alanlarıyla eşleştirme gibi çeşitli uygulamalar bu teknolojinin kullanım alanlarına örnek olarak gösterilebilir (127).

MÖ, veriden bir model oluşturmak veya öğrenmek için kullanılan bir tekniktir. Veri, belgeler, sesler, görüntüler gibi çeşitli bilgileri içerebilir. Model, MÖ sürecinin son ürünüdür. MÖ'nün modelleme sürecinde kullanılan verilere eğitim verileri denir. MÖ süreci, eğitim verilerinden modeli oluşturduktan sonra, modelin gerçek dünya verilerine uygulanmasını içerir. Bu süreç, Şekil 2.22'de gösterilmiştir. Şeklin dikey akışı öğrenme sürecini temsil ederken, eğitilen modelin gerçek verilere uygulanması yatay akış olarak adlandırılır (128).



Şekil 2.22 : Gerçek verilerle bir MÖ modelinin uygulanması (128)

MÖ algoritmaları öğrenme türüne bağlı olarak iki ana kategoriye ayrılır. Bunlar, gelecekteki çıktıları tahmin edebilmek için etiketlenmiş girdi ve çıktı verileri üzerinde bir model eğiten denetimli öğrenme ve girdi verilerinde gizli kalıpları veya içsel yapıları bulan denetimsiz öğrenmedir.


Denetimli öğrenme, MÖ sistemini eğitmek için örnek etiketli veriler sağlanarak bu verilere dayalı çıktının tahmin edildiği bir yöntemdir (129). Sistem, veri kümelerini anlamak ve her bir veri hakkında bilgi edinmek için etiketli verileri kullanarak bir model oluşturur (130). Eğitim ve işleme tamamlandıktan sonra, modelin performansını değerlendirmek için bir örnek veri sağlanarak model test edilir. Denetimli öğrenmenin temel amacı, girdi verilerini çıktı verileriyle eşleştirmektir. Örneğin, bir metnin sınıf etiketini veya duyarlılığını tahmin etmek, yani metin sınıflandırması, denetimli öğrenmeye bir örnektir. Denetimli öğrenme algoritmaları sınıflandırma ve regresyon olmak üzere iki ana kategoriye ayrılır. Sınıflandırma teknikleri, önceden tanımlanmış sınıfları kullanarak verileri kategorilere ayırır (131). Bu teknikler, etiketli röntgen görüntülerini kullanarak patolojileri tanımlama (132) ve genetik hastalıkların teşhisi için genetik verilerin sınıflandırılması (133) gibi tıbbi alanlarda, konuşma tanıma (134) ve kredi puanlama (135) gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. Regresyon yönteminde ise, değişkenler arasındaki ilişki analiz edilerek gelecekteki eğilimlerin tahmin edilmesi amaçlanır (131). Bu teknikler, pilin şarj durumu, elektrik yükü tahmini (136) ve finansal varlıkların fiyatları (137) gibi sürekli yanıtları tahmin etmek için kullanılır. Tıp alanında regresyon yöntemine bir örnek olarak hastalık ilerlemesinin tahmin edilmesi verilebilir. Örneğin, diyabet hastalarının kan şekeri seviyelerinin zaman

içindeki değişimini tahmin etmek amacıyla regresyon teknikleri kullanılabilir. Bu teknikler, hastaların geçmiş kan şekeri ölçümlerine dayanarak, gelecekteki seviyelerini tahmin etmeye yardımcı olabilir. Böylece hastanın tedavi planı optimize edilebilir ve erken müdahale fırsatları değerlendirilebilir (138).

Denetimsiz öğrenme, denetimden bağımsız bir öğrenme tekniğini ifade eder. Bu durumda, makine, etiketlenmemiş bir veri seti kullanılarak eğitilir ve herhangi bir denetim olmadan çıktıyı tahmin etmesi sağlanır (139). Denetimsiz öğrenme algoritmaları, sıralanmamış veri kümesini girdinin benzerliklerine, farklılıklarına ve örüntülerine göre gruplandırmayı amaçlar (129). En yaygın denetimsiz öğrenme görevleri arasında kümeleme, yoğunluk tahmini, özellik öğrenme, boyut azaltma, birliktelik kurallarını bulma ve anormallik tespiti yer alır. Kümeleme tekniği, bir veri kümesindeki örnekleri, özelliklerinin belirli kombinasyonlarına göre ayrı kümeler halinde gruplandırır. Örneğin, müşterileri satın aldıkları ürünlere göre gruplamak bir kümeleme uygulaması olabilir. Birliktelik kuralı algoritmaları, büyük bir veri kümesinin değişkenleri arasındaki tipik ilişkileri tanımlamayı ifade eder. Bu algoritmalar, çeşitli veri öğelerinin bağımlılığını belirler ve birleşmiş değişkenleri haritalar. Web kullanım madenciliği ve pazar veri analizi gibi alanlarda birliktelik kuralı algoritmaları sıklıkla kullanılmaktadır. Denetimsiz öğrenme algoritmalarının tıp alanındaki önemli bir örneği tıbbi görüntüleme verilerinde anormallik tespittir. Örneğin, beyin MR görüntülerinde anormal bölgelerin otomatik olarak tespit edilmesi için denetimsiz öğrenme kullanılarak anormal dokuların, sağlıklı dokulardan ayrıştırılması sağlanabilir. Bu, özellikle beyin tümörleri gibi hastalıkların erken teşhisinde yardımcı olabilir (127).

2.4.2.Derin Öğrenme

DÖ, birden çok katmanın kullanılmasıyla hem girdi verilerinden daha yüksek seviyeli özelliklerin çıkarılmasına dayanan bir tür MÖ algoritmasıdır (Şekil 2.23) (140).




Şekil 2.23: YZ, MÖ ve DÖ'nün tasviri

Bu algoritmalar, katmanlı bir yapı olan Yapay Sinir Ağları (YSA) kullanır. YSA'da, her bir algılayıcının yapısı insan beynindeki nöronlara benzer şekilde tasarlanmıştır. YSA, kendi kendine öğrenme ve karar verme yeteneğine sahiptir (141). DÖ ağları, bir girdi katmanı, bir çıktı katmanı ve bir veya daha fazla gizli katmandan oluşur. Bu gizli katmanlar, birbirlerine bağlı ağırlıklı düğümler veya nöronlar içerir. "Derin" terimi, sinir ağındaki gizli katmanların sayısını ifade eder. Geleneksel bir sinir ağında gizli katman sayısı iki veya üç iken, DÖ'de bu sayı daha fazladır. Bu, DÖ'nün geniş veri kümelerini eğitme yeteneğine işaret eder (142). DÖ algoritmaları, verileri birkaç katmandan geçirir; her katman, özellikleri aşamalı olarak çıkarır ve bunları bir sonraki katmana aktarır. Ardışık her katman, bir önceki katmanın çıktısını girdi olarak kullanır. İlk katmanlar, düşük seviyeli özellikleri çıkarırken, sonraki katmanlar özellikleri birleştirerek hiyerarşik bir yapı oluşturur (143).

DÖ, MÖ teorisinin temsili öğrenim veya özellik öğrenimi dalına dayanır. Bir gözlem, piksel başına yoğunluk değerlerinin bir vektörü olarak veya daha soyut bir şekilde bir dizi kenar, belirli bir şekle sahip bölgeler gibi birçok şekilde temsil edilebilir. DÖ'nün sağladığı yararlardan biri, denetimsiz veya yarı denetimli özellik öğrenimi ve hiyerarşik özellik çıkarımı için manuel çıkarılan özellikleri verimli algoritmalarla değiştirmektir (144). Bu bakımdan, DÖ, yapılandırılmamış verilerle uğraşırken çok sayıda özelliği işleme yeteneği sayesinde mevcut MÖ tekniklerinden daha iyi performans göstermektedir (145). MÖ algoritmalarında problem çözme, problemi farklı parçalara ayırmayı, bunları tek tek çözmeyi ve sonucu elde etmek için birleştirmeyi gerektirir.

Buna karşılık, DÖ, sorunu uçtan uca çözer (127). Derin sinir ağı, MÖ'nün nihai ürünü yerine geçer ve öğrenme kuralı, eğitim verilerinden modeli (derin sinir ağı) üreten algoritma haline gelir. Derin sinir ağının önemi, bilginin hiyerarşik olarak işlenmesi için karmaşık doğrusal olmayan modele ve sistematik yaklaşıma kapı açmış olmasında yatmaktadır (128). Şekil 2.24'te DÖ ve MÖ ile ilişkisi gösterilmiştir.



Şekil 2.24: DÖ Modeli ve MÖ ile ilişkisi


DÖ yöntemleri, uçtan uca özelliklerin otomatik olarak çıkarılmasını ve sınıflandırılmasını sağlar. Son on yılda, bir tür derin sinir ağı olan ESA, örüntü tanıma ile ilgili farklı görevlerde çığır açan sonuçlar elde etmiştir. İnsan görsel korteksinden esinlenen ESA'lar, görüntü tanıma problemlerinde çeşitli sınıfları ayırt eder (146, 147). Ancak, ESA büyük miktarda eğitim verisi gerektirir. Tıbbi görüntü analizi gibi alanlarda ESA kullanmak genellikle sıfırdan eğiterek, yeniden eğitmeden önce önceden eğitilmiş bir ağ kullanarak veya önceden eğitilmiş bir ağ hedef veri kümesinde ayarlayarak gerçekleştirilir (148). Bu zorluğun üstesinden gelmek için, ImageNet gibi çok sayıda görüntü üzerinde eğitilmiş ESA modellerinden bilgi aktaran bir transfer öğrenme yaklaşımı geliştirilmiştir (149). Bu yaklaşımda, modelin ilk katmanları kilitlenir veya ayarlanırken, son katmanlar hedef veri kümesi üzerinde eğitilir. Kaynak ve hedef veri kümeleri farklılık gösterse de model herhangi bir görüntüyü değerlendirirken genellikle aynı olan düşük seviyeli özellikleri çıkarır. Böylece, modeli eğitmek ve ek özellikler çıkarmak için büyük veri kümesi gereksinimini ortadan kaldırır. Bu teknik, eğitim süresini ve maliyetini azaltır (150). Transfer öğreniminde iki yaklaşım kullanılır. Birincisi, aktarılan modelin çıktı katmanını yeni veri setinin sınıf sayısına göre

özelleştirmek ve ardından ince ayar yapmaktır. Diğer yaklaşım ise, aktarılan modeli doğrudan bir özellik çıkarıcı olarak kullanmaktır (151).

2.4.2.1.Özellik Çıkarımı

Özellik çıkarımı, verilerin karmaşıklığını azaltmak, algoritmaların çalışmasını öğrenmek ve kalıpları daha belirgin hale getirmek için alan bilgisini özellik çıkarıcıların oluşturulmasına dahil eden bir süreçtir. Bu süreç zaman alıcı, uzmanlık gerektiren ve pahalı bir süreçtir. Uygulanan özelliklerin çoğu, bir uzman tarafından tanımlanmalı ve ardından MÖ'deki etki alanı ve veri türüne göre manuel olarak kodlanmalıdır. Özellikler, piksel değerleri, şekil, doku, konum ve yönelim gibi çeşitli öznitelikler olabilir. MÖ algoritmalarının performansı, özelliklerin ne kadar doğru bir şekilde tanımlandığı ve çıkarıldığına bağlıdır. DÖ algoritmaları, verilerden yüksek seviyeli özellikler çıkararak bu süreci otomatikleştirir. Bu, geleneksel MÖ'ye göre önemli bir avantaj sağlayan DÖ'nün temel özelliklerinden biridir. Sonuç olarak, DÖ, her problem için yeni özellik çıkarıcı geliştirme görevini azaltır ve verilerden daha etkili bir şekilde yüksek seviyeli özellikler elde etmeyi sağlar (127).

Derin özellik çıkarma, büyük bir veri kümesi olan ImageNet gibi önceden eğitilmiş bir ESA'dan elde edilen özelliklerin çıkarılmasına dayanır (149). Bu özellikler, evrişimli katmanlar kullanılarak çıkarılır ve bir özellik vektörü elde edilir. Daha sonra, bu özellik vektörleri yeni bir görev için MÖ sınıflandırıcılarına iletilir, örneğin Destek Vektör Makineleri (DVM), K-En Yakın Komşuluk (KNN) gibi veya tam bağlı katmanlardan oluşan bir sınıflandırıcıya (softmax) iletilir. Tüm modeli yeniden eğitmek yerine, yalnızca yeni sınıflandırıcı eğitilir. Bu yaklaşımın temel avantajı, önceden eğitilmiş modeli her eğitim döngüsünde çalıştırmak yerine, yalnızca yeni veriler üzerinde çalıştırılmasıdır, bu nedenle çok daha hızlıdır (152). Şekil 2.25'te, derin bir sinir ağının giriş katmanına gelen bir görüntüden düşük seviyeden yüksek seviyeye çıkarılan özniteliklerin görüntü tanınmasında nasıl kullanıldığına dair bir örnek verilmiştir.



Şekil 2.25: Görüntülerin iki tarafından özellik çıkarma işleminin bir örneği (153)


2.4.2.2. Transfer Öğrenme

Transfer öğrenimi, bir modelin bir problemde edindiği öğrenmeyi başka bir problemde kullanabilmesine olanak tanıyan bir tekniktir. Bu yaklaşım, genellikle bir modelin kapsamlı bir veri kümesi üzerinde eğitilmiş olduğu durumlarda kullanılır ve ardından bu öğrenmenin başka bir veri kümesine uyarlanması amaçlanır. Transfer öğrenimi, modelin daha hızlı bir şekilde eğitilmesine yardımcı olur ve aynı zamanda hesaplama açısından daha ekonomiktir. Transfer öğrenimi, büyük bir veri kümesinden bilgi edinen bir modelin, daha az etiketli gözlem içeren daha küçük bir veri kümesindeki performansını artırabilir. DÖ modellerinin son katmanları genellikle veri kümesine özgü bilgiler içerir. Bu nedenle, bu son katmanları başka bir veri kümesine uyarlamak, modelin yeni verilere uyum sağlamasını sağlar. Bu şekilde, transfer öğrenimi, önceden eğitilmiş bir modelin bilgi ve deneyimini farklı bir bağlamda kullanılabilir hale getirir (154).

Sınıflandırma için kullanılabilecek birçok önceden eğitilmiş transfer öğrenme modeli bulunmaktadır. Önceden eğitilmiş bir model, benzer nitelikteki bir sorunu ele almak için geliştirilmiş bir modeldir. Sınıflandırma sorunları genellikle çok büyük veri setleriyle

eğitilir. Benzer bir sorunu ele almak için sıfırdan bir model oluşturmak yerine, başka bir sorun üzerinde eğitilen model bir başlangıç noktası olarak kullanılabilir. Hedef etki alanından veri kullanılabilirliğine bağlı olarak, tüm katmanlar yeniden eğitilebilir veya yalnızca son (tam bağlı) katman yeniden eğitilebilir. Bu yaklaşım, sinir ağlarının nispeten daha küçük veri kümeleri kullanılarak yeni görevler için eğitilmesine olanak tanır, çünkü yararlı düşük seviyeli özellikler kaynak etki alanı verilerinden öğrenilir (155, 156).

Herhangi bir DÖ modelinin performansı mevcut eğitim verilerine dayanır. Daha büyük veri kümeleri daha iyi öğrenme ve daha iyi performans sağlar. Ancak, sağlık uygulamalarında gizlilik endişeleri nedeniyle büyük eğitim verilerinin kullanılabilirliği her zaman mümkün olmayabilir. Bu yetersiz veri sorununu çözmek için transfer öğrenme yöntemi uygulanır. Transfer öğrenme, daha büyük bir veri kümesi üzerinde zaten eğitilmiş olan ve daha sonra yeni hedef görev için ayarlanan ağırlıkları kullanır (154, 157).




Şekil 2.26 : A ve B ağlarındaki ilk katmanların aynı olduğu transfer öğrenme yaklaşımının gösterimi (158).

2.4.2.3.Uçtan Uca Öğrenme

Uçtan uca DÖ, karmaşık görevler için tek bir sinir ağının eğitildiği bir MÖ tekniğidir ve herhangi bir manuel özellik çıkarımı olmaksızın doğrudan ham girdi verilerini kullanır. Bu teknik, büyük ölçekli veri kümelerinin oluşturulması sayesinde, konuşma tanıma, makine çevirisi, yüz algılama gibi çeşitli alanlarda devrim yaratmıştır. Geleneksel MÖ’de, eğitim veri hattı en az iki aşamadan oluşur: İlk aşamada ham girdi verilerinden ayırt edici özellikler üretilir. Bu, her görev için en alakalı özellikleri belirlemek üzere alan bilgisinden yararlanılarak yapılır. Bir sonraki aşamada ise çıkarılan özellikler alınarak tahminler oluşturulur. Ancak, bu prosedür zaman alıcıdır ve alana özgü bilgi gerektirir (159).

Uçtan uca DÖ, manuel çıkarılan özellikleri gerektirmez ve girdi çıktı eşlemesini doğrudan verilerden öğrenir. DÖ algoritmaları, genellikle büyük bir sinir ağına (genellikle büyük veri kümesi üzerinde eğitilmiş) girdi verilerini ileterek çalışır. Sonuç olarak, ağ girdi verilerini işler ve tahminler oluşturmak için ilgili özellikleri otomatik olarak çıkarır. Bu yöntem, manuel mühendislik gerektirmez ve zamanla çaba miktarını azaltır. Bu tekniğin başarısı, eğitim sırasında kullanılan büyük miktardaki veri ve sinir ağlarının çok sayıda veri üzerinde eğitilerek yüksek seviyeli özellikleri öğrenme yeteneğine dayanmaktadır (160).




Şekil 2.27 : Manuel özellik çıkarma ile karşılaştırmalı olarak uçtan uca öğrenme kavramının gösterimi (161).

2.4.3.Evrişimli Sinir Ağları (ESA)

ESA, görüntülerdeki örüntüleri tanımlamak için öğrenilebilir filtreler veya çekirdekler kullanan bir DÖ algoritmasıdır (162). Bu filtreler, kenarlar, doku, renk ve şekiller gibi özellikleri belirlemek için kullanılır. ESA, paralel olarak çalışan ve biyolojik sinir sistemlerinden esinlenen basit öğeleri kullanarak birden fazla doğrusal olmayan işlem katmanını birleştirir. Genellikle çok sınıflı sınıflandırma için bir sinir ağı kullanılır. ESA'nın özelliği, özellik çıkarıcıyı manuel olarak tasarlamak yerine eğitim sürecine dahil etmesidir. Özellik çıkarıcısı, eğitim süreciyle belirlenen özel tür sinir ağlarından oluşur. Bu, ESA'nın özellik çıkarma tasarımını otomatikleştirilmiş bir süreç dönüşürmesini sağlar, bu da en önemli özelliği ve avantajıdır (128).

Bir ESA, özellik çıkarma ağı ve sınıflandırma ağı arasında seri bir bağlantıdan oluşur. Giriş görüntüsü özellik çıkarma ağına girer. Burada, görüntünün özellikleri çıkarılır ve elde edilen özellik sinyalleri sınıflandırma sinir ağına iletir. Sınıflandırma sinir ağı, özelliklere dayanarak görüntünün sınıfını belirler ve çıktıyı üretir. Özellik çıkarma sinir ağı, evrişim katmanı, aktivasyon fonksiyonu ve havuzlama katmanı çiftlerinden oluşur. Evrişim katmanı, görüntüyü dönüştürmek için evrişim işlemini kullanır ve bir dijital filtre koleksiyonu olarak düşünülebilir. Havuzlama katmanı, komşu pikselleri tek bir pikselde birleştirerek görüntünün boyutunu ve ağın öğrenmesi gereken parametre sayısını azaltır. Bu işlemler onlarca veya yüzlerce katman üzerinde tekrarlanır ve her katman farklı özellikleri tespit etmeyi öğrenir. Özellik tespitinden sonra, ESA mimarisi sınıflandırmaya geçer. Sondan bir önceki katman, ağın tahmin edebileceği sınıf sayısı olan K boyutlu bir vektör çıkaran tam bağlı bir katmandır. Bu vektör, sınıflandırılan herhangi bir görüntünün her bir sınıfı için olasılıkları içerir. ESA mimarisinin son katmanı, sınıflandırma çıktısını sağlamak için bir softmax işlevi kullanır. Bu işlem, görüntünün hangi sınıfa ait olduğunu belirlemek için olasılık dağılımını üretir (163, 164).



Şekil 2.28: ESA model mimarisi (165)


2.4.3.1.ESA Katmanları

2.4.3.1.1. Giriş Katmanı

Giriş katmanı, ESA'nın ilk katmanını oluşturur. Bu katmanda, ağa ham veriler doğrudan sağlanır. Örneğin, eğer giriş bir görüntü ise, bu görüntüler her bir pikselin renk yoğunluğunun değerlerini içeren tensörler olarak temsil edilir (163). Tensörler, çok boyutlu matrislerdir ve görüntünün boyutlarına göre farklılık gösterebilir. Bir ağdaki giriş katmanındaki görüntünün boyutu önemlidir çünkü bu boyutlar ağın genel performansını etkiler. Büyük girdi boyutları, bellek kullanımını artırır ve ağın parametre sayısını artırarak ağın hızını yavaşlatabilir. Ancak, daha büyük girdi boyutları genellikle daha fazla özellik çıkarılmasına izin verir, bu da daha iyi sonuçlar elde edilmesine yardımcı olabilir. Diğer yandan, küçük girdi boyutları daha az bellek kullanımı ve daha az parametre sayısı gerektirir, bu da ağın daha hızlı çalışmasını sağlayabilir. Ancak, daha küçük girdi boyutları genellikle daha az özellik çıkarımı anlamına gelir ve bu da ağın performansını düşürebilir. Bu nedenle, giriş katmanındaki görüntünün boyutu, ağın hızı, bellek kullanımı ve performansı açısından dikkate alınması gereken önemli bir faktördür (166).

2.4.3.1.2. Evrişim Katmanı

Evrişim katmanları, ESA yapısının temel bileşenleridir ve özellik çıkarma işlemini gerçekleştirirler. Bu katmanlar aynı zamanda özellik haritalarını oluştururlar. Evrişim katmanları, ağa verilen giriş görüntüsünden çeşitli özellikleri çıkarmak için filtreler kullanır (167). Bu filtreler, farklı boyutlarda olabilir, genellikle 2x2, 3x3, 5x5 gibi boyutlara sahip olabilirler. Bu filtreler, görüntüye evrişim işlemi uygulanarak özellik haritası oluşturulur. Evrişim işlemi, bir matrisin filtre görevi görerek diğer matrisin üzerinde kaydırıldığı ve örtüşen elemanların çarpımlarıyla elde edilen sonuçların toplandığı bir doğrusal işlemdir (163). Evrişim katmanlarının eğitimi sırasında, her öğrenme iterasyonunda filtrelerin katsayıları değiştirilerek ağın özelliklerinin belirlenmesine katkıda bulunulur (166). Giriş verilerindeki özellikler, köşeler, kenarlar, lekeler, eğriler, şekiller, dokular, yoğunluk örüntüleri ve diğer soyut detaylar gibi anlamlı bilgileri içerebilir. Bu özellikler, ağın bir görevi öğrenmesini ve genelleştirmesini sağladığından önemlidir (163).



Şekil 2.29: Evrişim katmanında bir filtre ile birlikte evrişimin nasıl gerçekleştiğini gösteren bir görsel (168)

Özellik haritası, her filtre tarafından üretilen evrişimli çıktıların (bir sapma değeri eklenmiş) bir matriste düzenlendiği yapıdır. Bu matris, her bir filtre tarafından çıkarılan özellikleri içerir ve her filtre kendi özellik haritasını üretir. Dolayısıyla, bir katmandan elde edilen tek kanallı özellik haritasının sayısı, içerdiği filtre sayısına eşittir. Her filtre

tarafından üretilen evrişimli çıktılar, bir sonraki katmana aktarılacak şekilde bir araya getirilir ve bu matrise özellik haritası denir. Özellik haritası, filtrelerin özelliklerini saklar ve her bir filtre tarafından üretilen özellikleri içerir. Aktivasyon fonksiyonları uygulandıktan sonra nöronların çıkışlarını gösteren bir özellik haritası, aktivasyon haritası olarak da adlandırılabilir. Bu haritalar, ağı öğrenme sürecinde önemli bilgiler içerir ve sonraki katmanlara aktarılarak özellik çıkarma işlemine devam edilir (168).


2.4.3.1.3. Toplu Normalizasyon Katmanı

Toplu normalizasyon katmanı (Batch Normalization), her kanal için bağımsız olarak tüm gözlemler genelinde mini bir veri grubunu normalleştirir. Bu teknik, DÖ sinir ağlarındaki bir katmanın girdilerini otomatik olarak standartlaştırmak için tasarlanmıştır. Toplu normalizasyon bir kez uygulandığında, bir sinir ağının eğitim sürecini önemli ölçüde hızlandırma etkisine sahiptir ve bazı durumlarda modelin performansını artırır. Teknik olarak, bu katman girdileri standartlaştırarak dönüştürür, yani sıfır ortalamaya ve bir standart sapmaya sahip olacaklardır. Eğitim sırasında, katman her girdi değişkeni için istatistikleri takip eder ve bunları verileri standartlaştırmak için kullanır. Toplu normalizasyon, birçok DÖ sinir ağı türünde kullanılabilir (169). Araştırmacılar, toplu normalizasyon katmanlarının eklenmesinin, aynı doğruluğa ulaşan bir ağı eğitmek için 14 kat daha az eğitim adımına ihtiyaç duyulabileceğini göstermiştir. ESA'nın eğitimini hızlandırmak ve ağı başlatılma performansını iyileştirmek için evrişim katmanları ile Düzeltilmiş Doğrusal Birim (Rectified Linear Unit / ReLU) gibi doğrusal olmayan katmanlar arasına toplu normalleştirme katmanları eklenmektedir (169, 170).

2.4.3.1.4. Etkinleştirme (Aktivasyon) katmanı


Aktivasyon katmanları, ESA'nın önemli bir parçasıdır ve doğrusal olmayan bir özellik kazandırmak için kullanılırlar. Evrişim katmanından sonra gelirler ve üretilen çıktıyı ayarlamak ve sınırlamak için kullanılırlar (171). Bu katmanın amacı, evrişim katmanından gelen doğrusal çıktıyı doğrusal olmayan bir forma dönüştürerek ağı daha hızlı öğrenmesini sağlamaktır. Aktivasyon fonksiyonları olarak da adlandırılan bu fonksiyonlar, birçok farklı çeşide sahiptir. ESA bağlamında en yaygın olarak kullanılan aktivasyon fonksiyonu ReLU'dur.

ReLU, matematiksel olarak $f(x)=\max(0, x)$ şeklinde ifade edilir. Bu fonksiyon, girdinin tüm negatif değerlerini sıfıra dönüştürürken pozitif değerlerin girişle aynı kalmasını sağlar (172). Bu fonksiyonun ana avantajlarından biri, girdi negatif olduğunda çıktının sıfır olması ve girdi pozitif olduğunda girdiyle aynı değere sahip olmasıdır. Dolayısıyla, ReLU'nun gradyanı her zaman 1 veya 0'dır, bu da daha derin sinir ağlarında gradyan kaybı sorununu önlemeye yardımcı olur (173). ReLU'nun diğer avantajlarından biri, diğer aktivasyon fonksiyonlarına kıyasla daha düşük bir hesaplama yüküne sahip olmasıdır (174).



Şekil 2.30 : ReLU aktivasyon fonksiyonu grafiği (173)


Aktivasyon fonksiyonu özellik haritasındaki düğümlere uygulanır. Bu fonksiyon pozitif değerleri aynı değerle çıkartırken, negatif değerleri bir eşikte sıfıra indirir. Bu şekilde, doğrusal olmayan bir özellik haritası elde edilir ve ağın daha karmaşık ve daha genel geçer özellikleri öğrenmesine yardımcı olur. Özellikle ReLU gibi aktivasyon fonksiyonları, negatif değerleri sıfıra indirerek doğrultulmuş bir öznetelik haritası oluşturur. Bu, ağın daha derin özellikler öğrenmesine ve daha etkili bir şekilde genelleştirme yapmasına olanak tanır (175).



Şekil 2.31: ReLU aktivasyon fonksiyonuna bir örnek (175)

2.4.3.1.5. Havuzlama Katmanı


Havuzlama işlemi veya havuzlama katmanı genellikle ESA'larda kullanılır ve sıklıkla parametre sayısını azaltmak ve hesaplama yükünü düşürmek için tercih edilir. Bu katmanlar, bir sonraki evrişim katmanı için girdi boyutunu azaltarak derinliği etkilemezler. Yani havuzlama işlemi sonrasında giriş verisinin yükseklik ve genişlik değerleri azalırken derinlik, yani kanal sayısı aynı kalır. Havuzlama katmanları, giriş dizilerinin örnekleme (downsampling) işlemi için kullanılır. Bu işlem, giriş matrisini alt matrislere böler ve her alt matrisi temsil edecek bir değer seçer, böylece örnekleme gerçekleştirilir (166). İki yaygın havuzlama yöntemi vardır: maksimum havuzlama ve ortalama havuzlama katmanları. Maksimum havuzlama, alt matris içindeki maksimum değeri seçerek örnekleme yaparken, ortalama havuzlama, alt matrisin ortalamasını alır. Yapılan çalışmalar, maksimum havuzlamanın nesne sınıflandırma görevlerinde ortalama havuzlamadan daha etkili olduğunu göstermiştir. Bu nedenle, maksimum havuzlama daha sık tercih edilen bir yöntemdir (176).



Şekil 2.32: 2×2 filtre boyutu ve 2×2 adım ile maksimum havuzlama ve ortalama havuzlama için örnek (177)

2.4.3.1.6. Tam Bağlantılı Katman


Tam bağlantı katmanları, bir ESA'da evrişim, ReLU ve havuzlama katmanlarından sonra gelir. Bu katmanlar, girdi görüntüsünün sınıflandırma veya segmentasyon gibi diğer görevleri gerçekleştirmek için standart bir sinir ağı mimarisi kullanan bir veya daha fazla tamamen bağlı katmandan (yoğun katmanlar olarak da bilinir) geçirilir. Tam bağlantı katmanı için özellik haritası 1 boyutlu bir özellik vektörüne dönüştürülür, buna düzleştirme denir. Bu katman, bir önceki katmanın tüm alanlarına bağlı olduğu için tam bağlantı katmanı olarak adlandırılır. Tam bağlantı katmanları, görüntüleri farklı kategorilerde sınıflandırmak için kullanılır (178). Evrişimli ve havuzlama katmanlarının çıktısı, giriş görüntüsünün önemli özelliklerini temsil eden bir dizi üst düzey özelliktir. Tamamen bağlantılı katmanların rolü, bu öğrenilmiş özellikleri kullanarak girdi görüntüsünün sınıfını veya etiketini tahmin etmektir. Yoğun bağlantılar nedeniyle, tam bağlantı katmanları çok sayıda parametreye ve yüksek hesaplama yüküne sahiptirler. Bir ağda tam bağlantı katmanı olmaması, ağın karmaşık özellikleri işleme yeteneğinden yoksun olmasına sebep olacak ve genel performansı önemli ölçüde düşürecektir (163).



Şekil 2.33: Tam bağlantılı katmanın yapısı. (179)

2.4.3.1.7. DropOut Katmanı

Dropout, derin sinir ağları için popüler bir düzenleme tekniğidir. Bu teknik, genellikle tam bağlantı katmanlarına uygulanan ve aşırı öğrenmeyi önlemeye yardımcı olan bir yöntemdir. Aşırı öğrenme, bir modelin eğitim verileri üzerinde çok iyi performans göstermesi durumunda ortaya çıkar, ancak yeni veri üzerinde genelleme yapma yeteneğini olumsuz yönde etkiler. Dropout ile, eğitim sürecinde sinir ağındaki belirli nöronların rastgele olarak bırakıldığı veya devre dışı bırakıldığı bir mekanizma uygulanır. Her iterasyonda, belirli bir olasılıkla (genellikle 0,3 gibi) her nöronun bağlantıları geçici olarak kapatılır. Bu, ağın her iterasyonda farklı bir altkümüsi üzerinde eğitilmesini sağlar. Devre dışı bırakılan nöronlar her eğitim adımında örneklenir, böylece bir adımda devre dışı bırakılan bir nöron bir sonraki adımda aktif olabilir. Dropout'un amacı, ağın her nöronuna aşırı bağımlılığı azaltarak ve her nöronu bağımsız olarak çalışmaya zorlayarak ağın daha genel bir temsil öğrenmesine yardımcı olmaktır. Bu, ağın daha basit bir şekilde temsil edilmesini sağlar ve aşırı öğrenmeyi önler, bu da genel performansı artırır (180).



Şekil 2.34: Dropout katmanının şematik diyagramı (181)

2.4.3.1.8. Sınıflandırma Katmanı

Çıkış katmanı, ESA'nın son katmanıdır ve ağın öğrendiği özelliklere dayanarak kararlar alır. Bu katman, genellikle tam bağlantı katmanı olarak bilinir ve tüm nöronları önceki

katmanla tam bağlantılıdır. Çıkış katmanındaki nöron sayısı, sınıflandırma görevleri için sınıf sayısına ve regresyon görevleri için regresyon çıktıların sayısına eşittir. Softmax aktivasyon fonksiyonu genellikle çıkış katmanında kullanılır. Bu fonksiyon, ağıın çıkışını sınıflar arasında bir olasılık dağılımına dönüştürür. Yani, her sınıf için ağıın tahmin ettiği olasılığı sağlar (163). Softmax fonksiyonu, çıkışları toplamı 1 olan bir olasılık dağılımına dönüştürerek sınıflandırma problemlerinde en yüksek olasılığa sahip sınıfı seçmemizi sağlar. Bu sayede, ESA çıkış katmanı, giriş verisinin işlenmesi ve özelliklerin öğrenilmesinden sonra, sınıflandırma veya regresyon gibi sonuçlar üretmek için kullanılır (171).

2.4.4. Diş Hekimliğinde Yapay Zekâ

YZ, diğer disiplinlerde olduğu gibi, diş hekimliği alanında da giderek artan bir kullanıma ve potansiyele sahiptir. Diş hekimliğinde YZ uygulamaları, başlıca teşhis, tedavi planlaması ve prognoz değerlendirmesi gibi klinik süreçlere entegre edilmektedir. Özellikle teşhis alanında, YZ algoritmaları, radyolojik görüntülerin otomatik analizi ve patolojik süreçlerin erken teşhisi gibi görevleri üstlenerek, tanısal doğruluğu artırmakta ve hekimlerin iş yükünü azaltmaktadır. Diş hekimliği bilişim sistemlerindeki gelişmeler, klinik karar verme süreçlerini destekleyen YZ tabanlı araçların ortaya çıkmasına neden olmuştur. Bu araçlar, sürekli gelişen algoritmalar ve MÖ teknikleri sayesinde daha hassas ve güvenilir hale gelmektedir. YZ araştırmalarının diş hekimliğinin tüm alt disiplinlerine yayılmasıyla birlikte, bu teknolojinin klinik uygulamalardaki yeri giderek daha önemli hale gelmektedir (182-184).

2.4.4.1. Restoratif Diş Hekimliğinde Yapay Zekâ

Diş çürükleri, en yaygın görülen diş hastalıkları arasında yer almakta ve bu nedenle erken aşamada tespit edilmeleri oldukça önem taşımaktadır. Geleneksel yöntemlerde, diş hekimleri diş problemleri ve görsel muayene yoluyla çürükleri tespit etmeye çalışırken, bu yöntemler diş hekiminin deneyimine bağlı kalmaktadır. Özellikle aproksimal yüzeyler gibi erişimi zor alanlarda çürüklerin belirlenmesi, bu yöntemin sınırlayıcı bir yanını oluşturur (185, 186).

Son dönemde YZ destekli sinir ağıları, diş çürüğü tespitini hızlandırmak ve daha hassas hale getirmek amacıyla kullanılmaya başlanmıştır. Çeşitli çalışmalarda, yapay sinir ağlarının diş çürüğü tespitinde yüksek doğruluk oranları sunduğu belirtilmiştir (187). Bunun yanı sıra YZ, diş restorasyonlarının tanımlanması ve sınıflandırılmasında da

etkili bir araç olarak kullanılmaktadır (188). Bu teknolojiler, tanı ve tedavi aşamalarının seçilmesinde önemli bir katkı sağlamaktadır.

2.4.4.2. Endodontide Yapay Zekâ

YZ'nin endodonti alanındaki önemi giderek artmaktadır. YZ'nin, periapikal lezyonların ve kök kırıklarının tespiti, kök kanalı sistem anatomisinin değerlendirilmesi, pulpa kök hücrelerinin canlılığını tahmin etme, çalışma uzunluğunun ölçümü ve retreatment prosedürlerinin başarı oranlarının öngörülmesi gibi çeşitli konularda faydalı olabileceğini gösteren birçok çalışma bulunmaktadır (189-191).

YZ'nin endodonti alanında yalnızca radyolojik analizlerde değil, genetik alanında da potansiyeli bulunmaktadır. Yapılan bir çalışmada, YZ radiküler kistler ve periapikal granülomların gen ekspresyonlarını analiz ederek bu iki durum arasındaki farklı biyolojik süreçleri belirlemiştir (192).

2.4.4.3. Ortodontide Yapay Zekâ

YZ'nin ortodonti alanındaki kullanımı hızla artmaktadır. YZ, diş çekimi gereksinimlerinin tahmini, maksimum ankraj kullanımının öngörülmesi, sınıf II ve III maloklüzyonlarda tedavi sonuçlarının tahmini, temporomandibular eklem osteoartritinin tespiti, sefalometrik analizler ve büyüme-gelişim dönemlerinin belirlenmesi gibi konularda kullanılmaktadır (193-197). Bu çalışmalar, YZ'nin ortodontik tedavi planlaması ve tanı süreçlerinde önemli bir araç olduğunu ve diş hekimlerinin iş yükünü azaltarak daha hassas ve öngörülebilir sonuçlar sunduğunu göstermektedir.

2.4.4.4. Ağız, Diş ve Çene Cerrahisinde Yapay Zekâ

YZ'nin ağız, diş ve çene cerrahisi alanındaki kullanımı her geçen gün daha da genişlemekte ve birçok klinik uygulamaya entegre edilmektedir. Yapılan çalışmalara göre, YZ özellikle ortognatik cerrahi sonrası görüntü tahminlerinin iyileştirilmesi ve yüz estetiği gibi konularda hekimlere yardımcı olabilmektedir. Bu tür simülasyonlar hem tedavi planlamasını iyileştirmekte hem de hastaların tedavi sürecine katılımını artırmaktadır (198, 199). YZ ayrıca üçüncü molar diş çekimi gibi yaygın cerrahi prosedürlerde, sinir parestezisinin tahmin edilmesi için kullanılmaktadır. Bu alanda yapılan çalışmalarda, panoramik radyografler üzerinden YZ algoritmaları kullanılarak sinir hasarı riskinin tahmin edilebildiği gösterilmiştir (200).

Bunun yanı sıra, odontojenik lezyonların tespiti de YZ'nin önemli bir kullanım alanıdır. Ameloblastom ve odontojenik keratokist gibi tümörlerin panoramik radyografilerde tespiti, YZ ile başarılı bir şekilde gerçekleştirilebilmektedir. Bu tür lezyonların erken evrede tespiti, tedavi sürecini daha etkili hale getirmekte ve olası komplikasyonları azaltmaktadır (201).

İmplantoloji alanında da YZ'nin kullanımı hızla artmaktadır. YZ, implant tedavi planlamasında, dental implant markalarının tanınmasında ve osteointegrasyon kalitesinin değerlendirilmesinde faydalı olabilir. Özellikle peri-implant kemik kaybının ölçülmesi ve osteointegrasyon sürecindeki zorlukların tespit edilmesi gibi konularda YZ'nin kullanımı, cerrahi süreçlerin daha hassas ve başarılı bir şekilde yönetilmesine katkı sağlamaktadır (202).

2.4.4.5. Periodontolojide Yapay Zekâ

YZ periodontoloji alanında giderek daha yaygın kullanılmakta ve klinik uygulamalara entegrasyonu artmaktadır. YZ, periodontitisin erken teşhisi ve tedavi planlaması süreçlerinde diş hekimlerine yardımcı olabilecek önemli bir araçtır. Özellikle periodontal kemik kaybının tespiti, YZ algoritmalarının sıkça kullanıldığı bir alan olup, YZ'nin kemik kaybını daha doğru ve hassas bir şekilde değerlendirebildiği gösterilmiştir. Çeşitli çalışmalarda YZ, panoramik ve periapikal radyografilerde periodontal ve peri-implant kemik kaybını tespit etmede yüksek doğruluk oranlarına ulaşmıştır (203-206).

2.4.4.6. Protetik Diş Hekimliğinde Yapay Zekâ

YZ, protetik diş hekimliğinde teşhis, tedavi planlaması ve üretim süreçlerinde kullanılmaktadır (207). Özellikle implant planlaması (208), protezlerin hazırlanması (209), diş eksikliklerinin sınıflandırılması (210) gibi alanlarda YZ'den yararlanılmaktadır. YZ, bu alanlarda hataları azaltma ve doğruluğu artırma potansiyeline sahiptir (207).

2.4.4.7. Çocuk Diş Hekimliğinde Yapay Zekâ

YZ'nin çocuk diş hekimliğine uyarlanması, doğru teşhis ve tedavi planlamasında klinisyenlere önemli avantajlar sunar (211). YZ, çocukların diş sağlığını değerlendirmek (212), dental plak tespiti yapmak (213), süt dişlerini sınıflandırmak (214) ve erken çocukluk çürüklerini önceden tahmin etmek (215) gibi alanlarda kullanılmaktadır. YZ,

özellikle çocukların iş birliğini artırarak diş tedavilerinin başarısını artırmakta, aynı zamanda çocukların oral sağlık programlarında eğitim almasına da yardımcı olmaktadır (211).

2.4.4.8. Ağız, Diş ve Çene Radyolojisinde Yapay Zekâ

YZ, ağız, diş ve çene radyolojisi alanında geniş bir kullanım alanına sahip olup, bu teknolojilerin günlük klinik pratiğe entegrasyonu giderek artmaktadır. Panoramik radyografi, intraoral radyografiler, KIBT ve USG görüntüleri üzerinde yapılan çalışmalar, bu görüntülerin analizi ve yorumlanmasında önemli ilerlemeler sağlamıştır. YZ, anatomik yapıların ve patolojilerin segmentasyonu, diş çürüğü ve periodontal hastalıkların tespiti, görüntü rekonstrüksiyonu ve adli tıp uygulamaları gibi pek çok alanda kullanılmaktadır (216).

Ayrıca, YZ teknolojileri, ağız, diş ve çene radyolojisinde tedavi planlaması ve hasta takibi süreçlerinde önemli bir rol oynamaktadır. Özellikle KIBT ve panoramik radyografi gibi ileri görüntüleme teknikleriyle elde edilen verilerin işlenmesi, YZ algoritmaları sayesinde hızlanmakta ve bu işlemlerin doğruluğu artmaktadır. Diş çürüklerinin tespiti, endodontik tedavi planlamaları, kemik yapısının değerlendirilmesi ve osteoporoz gibi kemik hastalıklarının teşhisi gibi alanlarda YZ destekli yazılımlar başarılı sonuçlar vermektedir (217-219).

Görüntü işleme uygulamalarının ötesinde, MÖ uygulamalarıyla hastaların ağız sağlığı açısından risk gruplarının belirlenmesi gibi ileri kullanım alanları da bulunmaktadır. YZ, bu sayede sadece görüntüleme alanında değil, aynı zamanda bireylerin sağlık durumlarının değerlendirilmesi ve kişiselleştirilmiş tedavi süreçlerinin geliştirilmesine de katkı sunmaktadır (220).

3. GEREÇ VE YÖNTEM

Bu çalışma, Gaziantep Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı'nda yürütüldü. Araştırmamıza başlamadan önce Gaziantep Üniversitesi Müdahalesiz Klinik Araştırmalar Etik Kurulu'nun 2024/03 sayılı onayı alındı. Çalışmaya katılan bireylerden Helsinki Deklarasyonu kararları doğrultusunda bilgilendirilmiş onam alındı.

3.1. Çalışma Dizaynı

Gaziantep Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı'na Şubat 2024 ile Ağustos 2024 tarihleri arasında başvuran 18 yaş ve üzeri toplam 312 bireyden oluşan bir çalışma grubu oluşturuldu, çeşitli sebeplerle kliniğimize başvuruda bulunan bu bireyler çalışmaya gönüllülük esasıyla dahil edildi. Katılımcıların Etik Kurul tarafından onaylanmış “Bilgilendirilmiş Onam Formu”nu imzalamalarının ardından, klinik muayeneleri gerçekleştirildi. Sonrasında bireylerin sağ ve sol submandibular tükürük bezleri USG ile görüntülendi. USG ile bezlerin ekojeniteleri, parankim iç yapısı, marjinleri ve vaskülarizasyonları 3 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanlık öğrencisi ve 7 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanı tarafından sınıflandırıldı. Daha sonra elde edilen bu görüntülerde YOLOv8 DÖ algoritmasının submandibular tükürük bezlerini segmente etmedeki başarısı ve VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 DÖ algoritmalarının ise sınıflandırma performansı değerlendirildi.

3.2. Klinik Muayene

Çalışmamız kapsamında, oral sorunların tanımlanması, tedaviye katkı sağlanması ve dental müdahalelerin uygulanması amacıyla çalışmaya dahil edilen tüm hastalarda ekstraoral ve intraoral klinik muayeneler gerçekleştirildi.

- Ekstraoral Muayene: Baş, yüz, deri, göz, kulak, burun, dudaklar, boyun ve lenf bezleri, temporomandibular eklem ve çiğneme kaslarının muayenesi yapıldı.
- İntraoral Muayene: Halitozis, yanak mukozası, dudak mukozası, dil, ağız tabanı, frenulumlar, gingiva, sert damak, yumuşak damak ve dişlerin muayenesi bu kapsamda gerçekleştirildi.

3.3. Çalışmaya Dahil Edilme ve Dahil Edilmeme Kriterleri

3.3.1. Çalışmaya dahil edilme kriterleri

- ✓ 18 yaş ve üzeri hastalar

3.3.2. Çalışmaya dahil edilmeme kriterleri

- ✓ Tükürük bezinin USG görüntülerinin YZ ile değerlendirmesini mümkün kılmayacak kadar belirgin neoplazm ve cerrahi geçmişi olan hastalar

3.4. USG Görüntülerinin Alınması ve Submandibular Bez Değerlendirmesi

Araştırmaya dahil edilen hastaların tümü Ağız, Diş ve Çene Radyolojisi Anabilim Dalı'nda bulunan GE LOGIQ S8 with XDclear USG cihazı (Şekil 3.1) ve 9L-D (2-8 MHz) lineer prob ve standart su bazlı akustik bağlantı jeli kullanılarak değerlendirildi. Ölçümü yapan kişiye ve cihaza bağlı farklılıkların giderilebilmesi amacıyla tüm görüntüleme işlemleri aynı gözlemci ve aynı cihaz ile yapıldı. Ölçümler sırasında hastalar sırt üstü yatar pozisyonda iken baş hiperekstansiyon pozisyonunda konumlandırıldı.



Şekil 3.1: Çalışmada kullanılan GE LOGIQ S8 with XDclear USG cihazı

Submandibular bez görüntülenmesinde hasta yatar pozisyonda ve baş hiperekstansiyonda iken gerçek zamanlı 2D gösterim moduna geçildi ve B modda inceleme sağlandı (Şekil 3.2).



Şekil 3.2: Submandibular tükürük bezinin USG incelemesinde hasta pozisyonu.

USG değerlendirmesi ekstraoral ve bilateral olarak gerçekleştirildi; 9L-D (2-8 MHz) linear prob transversal düzlemde mandibulanın alt kenarına paralel bir pozisyonda tutularak elde edilen görüntüler kaydedildi (Şekil 3.3).



Şekil 3.3: Submandibular tükürük bezinin USG incelemesinde probun pozisyonu.


Daha sonra bezlerin kanlanması renkli doppler aracılığıyla değerlendirmek amacıyla prob incelenecek bölge seçili durumda iken transversal olarak ayarlanarak “Color Flow (CF)” moduna basıldı, incelenecek alan genişliği monitörden takip edilerek pencere bez alanı ile sınırlı olacak şekilde ayarlandı (Şekil 3.4).



Şekil 3.4: USG cihazında B mod (yeşil kare) ve renkli doppler (color flow, CF) (mavi kare) için seçim paneli.

3.4.1.Ekojenite Değerlendirmesi


Submandibular tükürük bezlerinin parankimal yapısı ekojenite açısından incelendi. Ekojenite değerlendirme Hocevar ve ark. (6)’nın önerdiği skorlama sistemine göre değerlendirilerek tiroid beziyle karşılaştırıldı. Tiroid beziyle aynı ekojenitede ise izoeoik, tiroid bezine göre azalmış ekojenitede ise hipoeoik olarak sınıflandırıldı (Şekil 3.5).



Şekil 3.5: Submandibular bez parankiminin ekojenite açısından değerlendirilmesi. A. İzoeoik ekojeniteye sahip submandibular bez, B. Hipoekoik ekojeniteye sahip submandibular bez

3.4.2.Parankim İç Yapısı Değerlendirmesi

Submandibular tükürük bezlerinin parankimi; homojen, minimal heterojen ve belirgin heterojen olarak değerlendirildi (Şekil 3.6).






Şekil 3.6: Submandibular bez parankim iç yapısı açısından değerlendirilmesi. A. Homojen iç yapıya sahip submandibular bez. B. Minimal heterojen iç yapıya sahip submandibular bez. C. Heterojen iç yapıya sahip submandibular bez.

3.4.3.Marjin Değerlendirmesi

Submandibular tükürük bezlerinin marjinleri incelendi; düzenli, fokal düzensiz ve belirgin düzensiz olarak sınıflandırıldı (Şekil 3.7).








Şekil 3.7: Submandibular bezlerin marjinlerinin değerlendirilmesi. A. Düzenli marjine sahip submandibular bez, B. Fokal düzensiz marjine sahip submandibular bez, C. Belirgin düzensiz marjine sahip submandibular bez.

3.4.4. Vaskülarizasyon Değerlendirilmesi

Submandibular tükürük bezlerinin renkli doppler USG ile değerlendirilmesinde; bezlerin vaskülarizasyonu değerlendirilerek vaskülarizasyonun var/yok olduğu gözlemlendi, eğer sonuç var ise vaskülarizasyon santral/periferal/santral+periferal olarak değerlendirildi (Şekil 3.8).






Şekil 3.8: Submandibular bezlerin renkli doppler USG ile değerlendirilmesi A: vaskülarizasyon yok B: santral kanlanma C: periferel kanlanma D: santral+periferel kanlanma

3.4.5.Vaskülarizasyon Şiddetinin Değerlendirilmesi

Submandibular tükürük bezlerinin vaskülarizasyon şiddeti, renkli Doppler USG ile görüntüleme sırasında hiç damar görüntülenmemesi ya da üç veya daha az damar

segmenti içermesi durumunda zayıf kanlanma, üçten fazla kan damarının tükürük bezi boyunca görünür olması durumunda ise iyi kanlanma olarak tanımlandı (Şekil 3.9).



Şekil 3.9: Submandibular bezlerin vaskülarizasyon değerlendirilmesi A: zayıf kanlanma gösteren submandibular bez, B: iyi kanlanma gösteren submandibular bez

3.5.Model Geliştirilmesi

Model geliştirilirken Python programlama dili (v.3.10.12; Python Software Foundation, Wilmington, DE, ABD) ve Keras ve Tensorflow kütüphaneleri kullanıldı. Eğitim sürecinde, 62 GB RAM ve NVIDIA Tesla A100 grafik işlem birimi olan bir bilgisayar model eğitimi için kullanıldı.

3.6.Submandibular Tükürük Bezi Segmentasyonu

3.6.1.Derin Öğrenme Mimarisi


Çok sayıda algoritma, DÖ tabanlı nesne algılama ve anlamsal segmentasyon teknolojilerinin ilerlemesine katkıda bulunmaktadır. Bunlar arasında gerçek zamanlı nesne algılama ve anlamsal segmentasyon teknolojisi YOLO (You Only Look Once [Sadece Bir Kez Bak]) özellikle dikkat çekmiştir. Adından da anlaşılacağı üzere, YOLO algoritması nesneleri tek bir ileri geçişle tespit edebilmekte, böylece hızlı ve doğru nesne tespiti ve segmentasyonu mümkün olmaktadır (221).

3.6.1.1.YOLOv8

YOLOv5'i geliştiren şirket olan Ultralytics, Ocak 2023'te YOLOv8'i piyasaya sürdü. YOLOv8, Maksimum Olmayan Baskılama (NMS) sürecini hızlandıran ve kutu tahmin işlemlerinin sayısını azaltan anchor-free yaklaşımını izlemektedir. Ayrıca, YOLOv8 eğitim sırasında mozaik büyütmeyi de içermektedir. Ancak, bu artırmanın tüm eğitim süreci boyunca kullanılması halinde olumsuz etkileri olabileceği gözlemlenmiştir. Sonuç olarak, son on epok için devre dışı bırakılmıştır. Hızı, doğruluğu ve basitliği nedeniyle YOLOv8, nesne tanıma, görüntü segmentasyonu ve görüntü sınıflandırması ile ilgili çok çeşitli görevler için oldukça iyi bir seçimdir (222).

3.6.2.Görüntü Ön İşleme

Elde edilen USG görüntüleri Roboflow, Inc., Des Moines, Iowa, USA yazılımı ile öncelikle YZ'nin submandibular tükürük bezinin tespit performansını ölçmek amacıyla herhangi bir sınıflama yapılmadan, sadece submandibular tükürük bezleri olarak 3 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanlık öğrencisi ve 7 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanı tarafından poligonal olarak etiketlendi (Şekil 3.10.).



Şekil 3.10: USG görüntüleri üzerinde submandibular bezlerin poligonal etiketleme işlemi.

Elde edilen USG görüntüleri rastgele olarak eğitim grubu (%70), doğrulama grubu (%15) ve test grubu (%15) olarak üçe bölündü.

Elde edilen USG görüntüleri algoritmanın en iyi performansta çalışabilmesi için *.tiff formatından *.jpg formatına dönüştürüldü ve 1442x899 pikselden 640x640 piksele yeniden boyutlandırıldı. Ayrıca eğitim verilerine;

- Otomatik Yönlendirme,
- 90° Döndürme: Saat yönünde, saat yönünün tersine
- Kırpma: $\pm 15^\circ$ Yatay, $\pm 15^\circ$ Dikey,
- Çevirme: Yatay, Dikey,
- Döndürme: -15° ile $+15^\circ$ arasında,
- Gri Tonlama: Görüntülerin %25'ine,
- Gürültü: Piksellerin %5'ine kadar,
- Kesme: Her biri %10 boyutunda 3 kutu,
- Mozaik,

Bulanıklaştırma: 2,5 piksele kadar uygulandı ve görüntü sayısı arttırılarak modelin öğrenme başarımının yükseltilmesi amaçlandı. Eğitim verilerinin arttırılmasından sonra gruptaki görüntü sayıları şu şekilde oluştu:

- Eğitim grubu: 1311 görüntü
- Doğrulama grubu: 94 görüntü
- Test grubu: 94 görüntü içermektedir.


3.7.Submandibular Tükürük Bezi Sonografik Parametrelerin Sınıflandırılması

3.7.1.Derin Öğrenme Mimarisi

3.7.1.1.Inception v3

Inception v3, görüntü tanıma görevlerinde yüksek performans elde etmek amacıyla geliştirilmiş bir DÖ mimarisidir ve önceki Inception ağlarının üzerine eklenen çeşitli iyileştirmelerle optimize edilmiştir. Bu model, daha az parametreyle yüksek doğruluk sağlamayı hedeflerken, hesaplama verimliliğini artıran yenilikler sunmaktadır (223).


Inception v3, büyük boyutlu konvolüsyonların (örneğin 5x5 veya 7x7 filtreler) hesaplama açısından maliyetli olmasını çözmek için bu büyük filtreleri daha küçük konvolüsyonlar kullanarak parçalar. Örneğin, 7x7 boyutundaki bir konvolüsyon işlemi yerine ardışık iki 3x3 konvolüsyon kullanarak aynı sonuç elde edilir, ancak bu yöntem hesaplama maliyetini önemli ölçüde azaltır. Bu yaklaşım, modelin karmaşık yapıları öğrenme kapasitesinden ödün vermeden verimliliği artırır (223).



Şekil 3.11. Inception V3 modelinin mimarisi (224)

3.7.1.2.Xception

İlk olarak Francois Chollet tarafından önerilen bu özel ESA, Inception ESA'dan uyarlanmıştır. Inception'da tipik olarak bulunan modüller, derinlemesine ayrılabilir konvolüsyonlarla değiştirilmiştir. Xception modeli, Inception v3 ile neredeyse aynı miktarda parametreye sahiptir ve bu da kısmen çok benzer mimariyi paylaşmalarından kaynaklanmaktadır. Xception, Inception'ın ileri bir versiyonu olarak düşünülebilir, çünkü Inception tarafından ortaya konan fikirleri Inception'ın şimdiye kadar önerilen herhangi bir versiyonundan çok daha ileri götürmektedir (225). Inception'ın kanallar arası korelasyonlar için 3x3 veya 5x5 konvolüsyonlarla uzamsal korelasyonları yakaladığı yerde, Xception bunun yerine her kanalda 1x1 konvolüsyonlar gerçekleştirir ve ardından bu çıktıların her birine 3x3 hesaplama ekler. Bu, Xception'ın tahminlerini yapmak için kullandığı derinlemesine ayrılabilir konvolüsyonlar oluşturur (226).




Şekil 3.12: Xception DÖ modelinin mimarisi (227)

3.7.1.3.VGG (Visual Geometry Group) 16

VGGNet, DÖ alanında yaygın olarak kullanılan modellerden biridir ve basit yapısı ile etkinliği, geniş bir kullanım alanına sahiptir. Bu modelin popülerliği, mimarisinin açık ve anlaşılır olması, küçük boyutlu evrişim çekirdekleri kullanılması ve özellikle bir DÖ modeli olarak sunduğu kullanım kolaylığından kaynaklanmaktadır. VGGNet, maksimum havuzlama ve ReLU aktivasyon fonksiyonlarıyla birlikte 3x3 boyutunda evrişim çekirdekleri kullanarak derin özellik çıkarımı gerçekleştirir. Ayrıca, üç tam bağlantılı katman modelin son aşamalarında sınıflandırma görevini üstlenir. Küçük evrişim çekirdeklerinin tercih edilmesi, modelin parametre sayısını yönetilebilir düzeyde tutarken, daha etkili bir eğitim ve test süreci sağlar. Bu küçük çekirdekler sayesinde, modelin daha fazla katmanla derinleştirilmesi mümkün olur, bu da modelin özellikle görüntü işleme gibi alanlarda daha başarılı performans göstermesine olanak tanır. Dolayısıyla, VGGNet mimarisi, derinliği ve hesaplama verimliliğiyle görüntü tabanlı görevlerde önemli bir avantaj sunar. Bu, daha derin ağların kullanımını teşvik eden tasarımın temel fikrini açıkça ifade eder. Giriş katmanından sonra VGG model katmanı gelir, bu katman beş bloktan oluşur. Önerilen model, 224x224 boyutundaki ön işlenmiş resimleri bir VGG modelini kullanarak giriş katmanında okur. Giriş katmanının ardından, katmanın ilk bloğu iki evrişim katmanı ile başlar ve havuzlama katmanı ile eşlik eder. İlk evrişim katmanı 64 filtreden oluşur. Havuzlama işleminden sonra, son resim boyutu 112x112 piksele küçülür. Her katman bloğunun neredeyse aynı

katmanlama düzeni vardır. İkinci blokta, özellikler 56x56 boyutuna küçülür ve ilk ve ikinci evrişim katmanlarında 128 filtre bulunur. Özellik haritası, üçüncü blokta 256 filtre ile üç evrişim katmanı ve maksimum havuzlama ile 28x28 boyutuna küçülür. Dördüncü bloktaki havuzlama katmanında özellik haritası 512 filtre ile üç evrişim katmanı ile 14x14 boyutuna daha da sıkıştırılır. Özellik haritası, beşinci ve son blokta 512 filtre ile üç evrişim katmanı ile 7x7 boyutuna daha da sıkıştırılır (228, 229).




Şekil 3.13: VGG16 mimarisi (230)

3.7.1.4.VGG 19

VGG19, VGG16 modelinin bir uzantısı olarak, görüntü analizi ve sınıflandırma görevleri için DÖ'de önemli bir ilerlemedir. Öncüsü gibi, VGG19 da basitliği ve pratikliğiyle övgü alır. Küçük 3x3 evrişim çekirdeklerinin kullanımını benimser, maksimum havuzlama katmanları ve ReLU aktivasyonlarıyla tamamlanır, ki bunlar da VGGNet ailesinin belirleyici özellikleridir. Bu tasarım felsefesinin arkasındaki mantık, daha derin bir ağı mümkün kılan daha küçük filtrelerin kullanılmasıdır, bu da daha etkili özellik öğrenimine yol açar. VGG19 mimarisinde, giriş katmanı beş farklı blokla takip edilir, her biri tutarlı bir katmanlama düzeni ile karakterizedir. Bloklarda ilerledikçe, her evrişim katmanındaki filtre sayısı artar, ağı giderek daha karmaşık ve soyut özellikler

çıkarmasını sağlar. Son blok, özellik haritalarının mekansal boyutlarını daha da azaltır ve giriş görüntüsünün son derece sıkıştırılmış bir temsili oluşturur. VGG19'un derin ve tutarlı mimarisi, daha derin ağların görüntü odaklı görevlerde üstün olduğu fikrini vurgular ve bilgisayarlı görüş için DÖ alanında VGGNet ailesinin mirasını daha da sağlamlaştırır (229, 231).



Şekil 3.14: VGG19 mimarisi (232)


3.7.1.5.MobileNet

MobileNet, TensorFlow'un ilk mobil görsel algılama modeli olarak mobil uygulamalar ve yerleşik görüntü işleme sistemleri için özel olarak tasarlanmıştır. DÖ alanında derin ayrılabilir evrişim tekniğini benimseyerek, daha hafif ve daha az parametre içeren bir sinir ağı elde etmeyi hedefler. Derin ayrılabilir evrişim, derinliksel ve noktasal evrişim olmak üzere iki temel işlemi birleştirir; derinliksel evrişim, her kanalı ayrı ayrı işleyerek uzamsal bir evrişim gerçekleştirirken, noktasal evrişim ise özellikleri birleştiren tek piksel genişliğinde bir evrişim yapar. Ayrıca, genişlik çarpanı ve çözünürlük çarpanı gibi özelliklerle daha küçük ve daha hafif modeller elde edilir. Genişlik çarpanı, her katmanın genişliğini azaltarak modelin boyutunu küçültürken, çözünürlük çarpanı giriş görüntülerinin ve katmanların boyutunu azaltarak hesaplama maliyetini düşürür. Bu sayede, MobileNet diğer standart evrişimlere kıyasla önemli ölçüde daha az hesaplama

maliyetiyle çalışabilir, mobil cihazlar ve gömülü sistemler için daha uygun bir çözüm sunar (233).

3.7.1.6.MobileNet v2

MobileNetV2, sıkıştırma katmanları ve ters çevrilmiş artık blokları kullanan oldukça verimli bir özellik dedektörüdür (234). Eğitim sürecinde, genelleme yeteneğini artırmak amacıyla veri artırımı kullanılır. Veri artırma teknikleri, görüntüleri döndürme, yakınlaştırma, kırpma gibi çeşitli işlemlerden geçirerek yeni eğitim örnekleri oluşturmayı sağlar. MobileNetV2 mimarisi, temel model olarak 17 dar boğaz (bottleneck) kalıntı bloğunu takiben 1×1 düzenli evrişim bloğu içerir. Bu model, özellik çıkarımı için yaygın olarak kullanılır. Modelin sınıflandırma aşamasını gerçekleştirmek amacıyla temel yapıya ek katmanlar eklenir. Bu ek katmanlar, düzleştirilmiş ortalama havuzlama katmanı, ReLU aktivasyon fonksiyonuna sahip 64 nöronlu yoğun bir katman ve son olarak softmax aktivasyon fonksiyonuna sahip 3 nöronlu bir çıktı katmanından oluşmaktadır (235).



Şekil 3.15: MobileNetv2 mimarisi (236)

3.7.2.Görüntü Ön İşleme

Elde edilen görüntüler 3 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanlık öğrencisi ve 7 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanı tarafından submandibular bezlerin ekojenitesi, parankim iç yapısı, marjinleri ve vaskülarizasyonu açısından değerlendirilip yukarıda belirtilen sınıflamalara göre etiketlendi. Daha sonra her bir sonografik parametre için görüntüler rastgele olarak eğitim grubu (%70), doğrulama grubu (%15) ve test grubu (%15) olarak üçe bölündü.

Gruplara göre görüntü sayıları şu şekildedir:

- Eğitim grubu: 436 görüntü
- Doğrulama grubu: 94 görüntü
- Test grubu: 94 görüntü içermektedir.

Görüntü verilerini işlemek için Keras'ın ImageDataGenerator sınıfı kullanıldı. Bu sınıftaki işlevler, veri artırma ve ön işleme işlemlerini kolaylaştırmak için kullanılır. Bu çalışmada kullanılan işlevler;

- rescale = 1.0/255: Görüntü piksellerinin değerlerini [0, 1] aralığına ölçekler. Bu, ağın daha iyi öğrenmesini sağlayabilir.
- horizontal_flip = True: Görüntüleri yatay olarak çevirir.
- vertical_flip = True: Görüntüleri dikey olarak çevirir.
- zoom_range = 0.2: Görüntüyü rasgele yakınlaştırır.
- shear_range = 0.2: Görüntüyü rasgele kaydırır.
- width_shift_range = 0.2: Görüntüyü yatay ekseninde rasgele kaydırır.
- height_shift_range = 0.2: Görüntüyü dikey ekseninde rasgele kaydırır.
- fill_mode = 'nearest': Kaydırma veya döndürme işlemlerinden kaynaklanan boş pikselleri doldurmak için kullanılacak dolgu modunu belirtir. "nearest" dolgu modu, boşlukları en yakın dolu pikselin değeri ile doldurur.

Tüm bu işlemler eğitim verisi üzerinde uygulanırken, doğrulama ve test verilerinde kullanılmadı. Bunun nedeni modelin gerçek dünya performansını daha doğru bir şekilde değerlendirmeye çalışmaktır.

3.7.3. Hiperparametre Ayarlanması

Modelin eğitim aşamasında, giriş verisinin boyutu (150, 150, 3) olarak ayarlandı ve her eğitim iterasyonunda 32 örneklik bir grup kullanıldı. Öğrenme oranı (learning rate) 0.001 olarak belirlendi ve eğitim sürecinde her bir model için 100 epokluk bir eğitim gerçekleştirildi. Optimizasyon algoritması olarak Adam kullanıldı ve bu algoritmanın parametreleri lr = 0.001, beta_1 = 0.9, beta_2 = 0.999, amsgrad = False, epsilon = 1e-7 olarak belirlendi.

Eğitim sırasında aşırı uyumu (overfitting) engellemek amacıyla Keras'ın EarlyStopping komutu kullanıldı. Bu komut, doğrulama kümesi doğruluğunda 3 epok boyunca herhangi bir iyileşme görülmediği takdirde eğitimi durdurarak, modelin aşırı uyum göstermesinin önüne geçer.

3.8.Eğitim Aşaması

DÖ algoritmaları, başlangıçta eğitim setiyle 100 epokla eğitildi. Ardından doğrulama seti sistem model tahminlerinin geliştirilmesinde kullanıldı. Eğitim ağırlıkları, model tahminlerinin iyileştirilmesi sonucunda elde edildi.

3.9.Test Aşaması

Eğitim aşamasında elde edilen ağırlıkların doğruluğu verilerin %15'i üzerinde test edildi. Test seti, sistem tarafından daha önce hiç görülmemiş görüntülerin etiketlerinden oluşmaktaydı.

3.10.İstatistiksel Analiz

Submandibular tükürük bezlerinin ekojeniteleri, parankim iç yapısı, marjinleri ve vaskülarizasyonlarının frekansı ve yüzdeleri belirlendi.

Model performanslarını değerlendirmek için karmaşıklık matrisi kullanıldı. Karmaşıklık matrisi, modelin tahminlerini gerçek değerlerle karşılaştırarak performansını değerlendirir. Ayrıca, Alıcı İşlem Karakteristiği (Receiver Operating Characteristic Curve-ROC) eğrileri oluşturuldu ve ROC eğrisinin altında kalan alan (Area Under Curve-AUC) hesaplandı. Böylece submandibular bez segmentasyonu için YOLOv8 modelinin; submandibular tükürük bezi sonografik parametrelerin sınıflandırılması için ise VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 olmak üzere 7 farklı modelin performansları değerlendirildi.

3.10.1.Karmaşıklık Matrisi Hesaplama Prosedürü

Modelin tükürük bezi segmentasyonu ve sınıflandırmasındaki başarısının değerlendirilmesi için aşağıdaki matrisler kullanıldı.

- ✓ Doğru pozitif (DP), modelin doğru bir şekilde pozitif olarak tahmin ettiği durumları ifade eder.
- ✓ Yanlış negatif (YN), modelin yanlış bir şekilde negatif olarak tahmin ettiği durumları ifade eder.

- ✓ Yanlış pozitif (YP), modelin yanlış bir şekilde pozitif olarak tahmin ettiği durumları ifade eder (237).

3.10.2. Performans Değerlendirilmesi

Veri setlerinin sınıflandırma performansını ölçmek için kullanılan ölçütler arasında doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru bulunmaktadır.

Doğruluk, sınıflandırma problemlerinde doğru tahminlerin toplam veri kümesine olan oranını gösterir (237). Hesaplama formülü:

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

Kesinlik, pozitif olarak tahmin ettiğimiz değerlerin gerçekte kaçının doğru olduğunu gösterir (237). Hesaplama formülü:

$$Kesinlik = \frac{DP}{DP + YP}$$

Duyarlılık, pozitif olarak tahmin etmemiz gereken işlemlerin ne kadarının pozitif olarak tahmin edildiğini gösterir (237). Hesaplama formülü:

$$Duyarlılık = \frac{DP}{DP + YN}$$

Kesinlik ölçütü, sınıflandırıcının performansını yanlış pozitifler ile açıklarken, duyarlılık ölçütü bu performansı yanlış negatifler ile açıklar.


F1 Skoru, kesinlik ve duyarlılık ölçütlerinin ağırlık ortalaması ile hesaplanan bir değerdir (237). Hesaplama formülü:

$$F1 Skoru = \frac{2 \times Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık}$$

Alıcı İşlem Karakteristik Eğrisi (ROC Eğrisi- Receiver Operating Characteristic Curve), ikili sınıflandırma performansını grafikte göstermek için kullanılır. Doğru pozitif oranı ölçütünün y eksenine, yanlış pozitif oranı ölçütünün x eksenine konumlandırılması ile çizilir (238).

Eğri Altında Kalan Alan (Area Under the ROC Curve- AUC), birden fazla sınıflandırıcıyı karşılaştırmak için kullanılan bir metriktir. AUC değeri, 0 ile 1 arasında

değer alabilir ve 1'e ne kadar yakınsa bu, sınıflandırmanın o kadar iyi olduğunu gösterir. Kısacası, alan arttıkça sınıflandırma yeteneği artar (238).




Şekil 3.16: ROC eğrisi ve eğri altındaki alan AUC grafiği (239)

3.10.3. Birleşim üzerinden kesişim (Intersection of Union, IoU)

Nesne tespiti çalışmalarında karşılaştırmalar yapmak için sıklıkla kullanılan bir metrik, IoU (Intersection over Union) metriğidir. Bu metrik, sistem tarafından tahmin edilen bölge ile gerçekte etiketlenmiş bölge arasındaki kesişimin toplam birleşime oranını ifade eder. Çakışma bölgesi ne kadar büyük olursa, IoU değeri 1'e o kadar yaklaşır ve bu, tahminin gerçek bölgeyle ne kadar iyi örtüştüğünü gösterir. Bu parametre genellikle eğitim aşamasında elde edilir (240).

Tükürük bezi segmentasyonunda IoU'ya dayalı olarak hesaplanan güven skoru için eşik değeri %50 olarak belirlendi. Bu, tahminlerin başarı oranını belirlemek için kullanılan bir kriterdir. %50'nin altında olan tahminler başarısız olarak kabul edildi.




Şekil 3.17: Birleşim üzerinden kesişim (Intersection of Union, IoU) metriği ölçümü
(241)



4.BULGULAR


4.1. Submandibular Tükürük Bezi Segmentasyonu

Çalışmamızda ilk olarak YOLOv8 DÖ algoritmasının USG görüntülerinde submandibular tükürük bezini segmente etme başarısı incelenmiştir. Modelin performansı değerlendirilirken karmaşıklık matrisi kullanılmıştır. Submandibular tükürük bezi segmentasyonu için YOLOv8 DÖ modelinin karmaşıklık matrisi grafiği Şekil 4.1'de gösterilmektedir.



Şekil 4.1: Submandibular tükürük bezi segmentasyonu için YOLOv8 algoritmasının karmaşıklık matrisi grafiği

Şekil 4.2, submandibular tükürük bezi segmentasyonunda kullanılan YOLOv8 DÖ modeline ilişkin ROC eğrisini ve AUC değerini göstermektedir.



Şekil 4.2: Submandibular tükürük bezi segmentasyonu için YOLOv8 algoritmasının ROC eğrisi ve eğri altındaki alan AUC grafiği

YOLOv8 modelinin submandibular tükürük bezi segmentasyonu için AUC değeri 1.00 olarak hesaplanmıştır.

Submandibular tükürük bezi segmentasyonu için test verilerinin değerlendirilmesinde DP, YP ve YN değerleri YOLOv8 için 94, 0, 0 olarak bulunmuştur. Bu değerlere göre hesaplanan doğruluk duyarlılık, kesinlik ve F1 değerleri Tablo 4.1’de sunulmaktadır.

Tablo 4.1: Submandibular tükürük bezi segmentasyonu için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri


Doğruluk	1.00
F1	1.00
Kesinlik	1.00
Duyarlılık	1.00


4.2.Submandibular Tükürük Bezlerinin Sonografik Parametrelerinin Sınıflandırılması

Submandibular tükürük bezlerinin sonografik parametrelerinin sınıflandırılması için VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 DÖ algoritmalarının sınıflandırma araçları kullanılmıştır.

4.2.1.Ekojenite Değerlendirmesi


Submandibular tükürük bezlerinin ekojeniteleri izoekoik ve hipoekoik olarak sınıflandırıldıktan sonra yukarıdaki DÖ algoritmaları ile değerlendirildi. İlgili modellerin performansı karmaşıklık matrisi ile değerlendirilmiştir (Şekil 4.3).





Şekil 4.3: Submandibular tükürük bezi ekojenite sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: hipoekoik Sınıf 1: izoekoik)

Şekil 4.4, submandibular tükürük bezi ekojenite sınıflandırmasında kullanılan VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 DÖ modellerinin ROC eğrilerini ve AUC değerlerini göstermektedir.



Şekil 4.4: Submandibular tükürük bezi ekojenite sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: hipoekoik Sınıf 1: izoekoik)


Submandibular tükürük bezi ekojenite sınıflandırması için VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 modellerinin doğruluk değerleri sırasıyla %94.6, %95.7, %94.6, %95.7, %94.6, %93.6 ve %97.8 olmuştur. DP, YP ve YN değerlerinden hesaplanan duyarlılık, kesinlik ve F1 skorları Tablo 4.2'de gösterilmiştir.

Tablo 4.2: Submandibular tükürük bezi ekojenite sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri

	F1	Kesinlik	Duyarlılık
VGG16	0.94	0.93	0.95
VGG19	0.94	0.96	0.96
Inceptionv3	0.92	0.90	0.95
Xception	0.94	0.96	0.96
MobileNet	0.94	0.94	0.95
MobileNetv2	0.93	0.92	0.93
YOLOv8	0.98	0.98	0.98


4.2.2.Homojenite Değerlendirmesi


Submandibular tükürük bezlerinin marjin iç yapısı homojen, minimal heterojen ve belirgin heterojen olarak sınıflandırıldıktan sonra DÖ algoritmaları ile değerlendirildi. Bu modellerin performansı karmaşıklık matrisi ile değerlendirilmiştir (Şekil 4.5).



Şekil 4.5: Submandibular tükürük bezi homojenite sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: homojen Sınıf 1: minimal heterojen Sınıf 2: belirgin heterojen)

Şekil 4.6, submandibular tükürük bezi homojenliğinin sınıflandırılmasında kullanılan VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 modellerine ait ROC eğrilerini ve AUC değerlerini göstermektedir.





Şekil 4.6: Submandibular tükürük bezi homojenite sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: homojen Sınıf 1: minimal heterojen Sınıf 2: belirgin heterojen)

Submandibular tükürük bezi homojenite sınıflandırması için en yüksek doğruluk oranına sahip model %93.6 ile MobileNetv2 olurken, VGG16, VGG19, Inceptionv3, Xception, MobileNet ve YOLOv8 modellerinin doğruluk değerleri sırasıyla %82.9, %81.9, %88.2, %85.1, %88.2 ve %91.4 olmuştur. DP, YP ve YN değerlerinden hesaplanan duyarlılık, kesinlik ve F1 skorları Tablo 4.3'te gösterilmiştir.


Tablo 4.3: Submandibular tükürük bezi homojenite sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri


	F1	Kesinlik	Duyarlılık
VGG16	0.83	0.82	0.83
VGG19	0.82	0.84	0.82

Inceptionv3	0.87	0.86	0.88
Xception	0.84	0.83	0.85
MobileNet	0.87	0.86	0.88
MobileNetv2	0.92	0.92	0.94
YOLOv8	0.91	0.90	0.91

4.2.3.Marjin Değerlendirmesi


Submandibular tükürük bezlerinin marjinleri düzenli, fokal düzensiz ve belirgin düzensiz olarak sınıflandırıldıktan sonra DÖ algoritmaları ile değerlendirildi. Bu modellerin performansı karmaşıklık matrisi ile değerlendirilmiştir (Şekil 4.7).





Şekil 4.7: Submandibular tükürük bezi marjın sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: düzenli Sınıf 1: fokal düzensiz Sınıf 2: belirgin düzensiz)

Şekil 4.8, submandibular tükürük bezi marjın sınıflandırılmasında kullanılan VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 modellerine ait ROC eğrilerini ve AUC değerlerini göstermektedir.



Şekil 4.8: Submandibular tükürük bezi marjin sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: düzenli Sınıf 1: fokal düzensiz Sınıf 2: belirgin düzensiz)


Submandibular tükürük bezi marjin sınıflandırması için en yüksek doğruluk oranına sahip model %74.4 ile MobileNet olurken, VGG16, VGG19, Inceptionv3, Xception, MobileNetV2 ve YOLOv8 modellerinin doğruluk değerleri sırasıyla %65.9, %65.9, %60.6, %54.2, %63.8 ve %72.3 olmuştur. DP, YP ve YN değerlerinden hesaplanan duyarlılık, kesinlik ve F1 skorları Tablo 4.4'te gösterilmiştir.

Tablo 4.4: Submandibular tükürük bezi marjin sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri

	F1	Kesinlik	Duyarlılık
VGG16	0.64	0.70	0.66
VGG19	0.63	0.71	0.66
Inceptionv3	0.58	0.67	0.61
Xception	0.50	0.46	0.54
MobileNet	0.74	0.75	0.74
MobileNetv2	0.59	0.55	0.64
YOLOv8	0.71	0.72	0.72


4.2.4.Vaskülarizasyon Değerlendirilmesi


Submandibular tükürük bezlerinin vaskülarizasyonları kanlanma yok, santral kanlanma, periferik kanlanma ve santral+periferik kanlanma olarak sınıflandırıldıktan sonra DÖ algoritmaları ile değerlendirildi. Bu modellerin performansı karmaşıklık matrisi ile değerlendirilmiştir (Şekil 4.9).



Şekil 4.9: Submandibular tükürük bezi vaskülarizasyon sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: kanlanma yok Sınıf 1: santral kanlanma Sınıf 2: periferel kanlanma Sınıf 3: santral+periferel kanlanma)

Şekil 4.10, submandibular tükürük bezi vaskülarizasyon sınıflandırılmasında kullanılan VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 modellerine ait ROC eğrilerini ve AUC değerlerini göstermektedir.





Şekil 4.10: Submandibular tükürük bezi vaskülarizasyon sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: kanlanma yok Sınıf 1: santral kanlanma Sınıf 2: periferel kanlanma Sınıf 3: santral+periferel kanlanma)

Submandibular tükürük bezi vaskülarizasyon sınıflandırması için en yüksek doğruluk oranına sahip modeller %89.3 ile Xception ve YOLOv8 olurken, VGG16, VGG19, Inceptionv3, MobileNet ve MobileNetV2 modellerinin doğruluk değerleri sırasıyla %86.1, %87.2, %87.2, %86.1 ve %86.1 olmuştur. DP, YP ve YN değerlerinden hesaplanan duyarlılık, kesinlik ve F1 skorları Tablo 4.5'te gösterilmiştir.


Tablo 4.5: Submandibular tükürük bezi vaskülarizasyon sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri


	F1	Kesinlik	Duyarlılık
VGG16	0.82	0.78	0.86
VGG19	0.85	0.86	0.87
Inceptionv3	0.85	0.84	0.87

Xception	0.85	0.81	0.89
MobileNet	0.85	0.83	0.86
MobileNetv2	0.84	0.83	0.86
YOLOv8	0.88	0.88	0.90

4.2.5.Vaskülarizasyon Şiddeti Değerlendirilmesi


Submandibular tükürük bezlerinin vaskülarizasyon şiddeti yetersiz kanlanma ve iyi kanlanma olarak sınıflandırıldıktan sonra DÖ algoritmaları ile değerlendirildi. Bu modellerin performansı karmaşıklık matrisi ile değerlendirilmiştir (Şekil 4.11).





Şekil 4.11: Submandibular tükürük bezi vaskülarizasyon şiddeti sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının karmaşıklık matrisi grafiği (Sınıf 0: yetersiz kanlanma Sınıf 1: iyi kanlanma)

Şekil 4.12, submandibular tükürük bezi vaskülarizasyon şiddeti sınıflandırılmasında kullanılan VGG16, VGG19, Inceptionv3, Xception, MobileNet, MobileNetv2 ve YOLOv8 modellerine ait ROC eğrilerini ve AUC değerlerini göstermektedir.



Şekil 4.12: Submandibular tükürük bezi vaskülarizasyon şiddeti sınıflandırması için VGG16 (A), VGG19 (B), Inceptionv3 (C), Xception (D), MobileNet (E), MobileNetv2 (F) ve YOLOv8 (G) algoritmalarının ROC eğrisi ve AUC grafiği (Sınıf 0: yetersiz kanlanma Sınıf 1: iyi kanlanma)

Submandibular tükürük bezi vaskülarizasyon şiddeti sınıflandırması için en yüksek doğruluk oranına sahip model %100 ile YOLOv8 olurken, VGG16, VGG19, Inceptionv3, Xception, MobileNet ve MobileNetV2 modellerinin doğruluk değerleri sırasıyla %94.6, %94.6, %94.6, %93.6, %96.8 ve %95.7 olmuştur. DP, YP ve YN değerlerinden hesaplanan duyarlılık, kesinlik ve F1 skorları Tablo 4.6’da gösterilmiştir.

Tablo 4.6: Submandibular tükürük bezi vaskülarizasyon şiddeti sınıflandırılması için test verilerinin değerlendirilmesinde F1, kesinlik ve duyarlılık değerleri

	F1	Kesinlik	Duyarlılık
VGG16	0.94	0.94	0.95
VGG19	0.94	0.94	0.95
Inceptionv3	0.95	0.95	0.95
Xception	0.93	0.93	0.94
MobileNet	0.97	0.97	0.97
MobileNetv2	0.95	0.96	0.96
YOLOv8	1.00	1.00	1.00

5.TARTIŞMA

Diyabet, SS, romatoid artrit ve lupus gibi metabolik ve otoimmün hastalıkların yanı sıra bakteriyel ve viral enfeksiyonların, tükürük bezlerinin yapısını ve fonksiyonlarını olumsuz etkilediği bilinmektedir. Bu nedenle, söz konusu hastalıkların ve tükürük bezi hastalıklarının teşhis ve tedavi süreçlerinde tükürük bezlerinin değerlendirilmesi, doğru tanıya ulaşılmasında ve tedavi planlarının kişiselleştirilmesinde oldukça önemlidir (242-246).

Tükürük bezi hastalıklarının doğru teşhis ve etkili tedavi planlaması için USG, direkt radyografi, sialografi, MRG, BT, sintigrafi ve PET gibi görüntüleme yöntemlerine başvurulur. Bu yöntemler, tükürük bezlerinin yapısını, işlevini ve olası hastalıkları değerlendirmede farklı roller üstlenir. Yöntem seçimi, hastanın şikayetleri, tıbbi öyküsü ve şüphelenilen hastalık türüne göre belirlenir (48).

MRG, yumuşak doku kontrastı ve uzaysal çözünürlüğü açısından avantajlı bir yöntemdir ve kas ile tümör arasındaki arayüzü değerlendirmede BT'den üstündür. Ayrıca iyonize radyasyon kullanmama avantajına da sahiptir. MRG, malign tümörlerin perinöral yayılımını, derin lob uzanımını veya meningeal infiltrasyonu değerlendirmeye olanak tanır (247, 248). Parafaringeal boşluğun görüntülenmesinde tercih edilen yöntemdir. T1 ağırlıklı görüntüler, parotis lezyonlarının çoğunu, bezin hiperintens arka planına karşı tanımlar ve tümörün sınırının, infiltrasyon paterninin ve özellikle uzanım derinliğinin iyi bir şekilde değerlendirilmesini sağlar (249).

MRG, fasiyal sinirin görüntülenmesinde en iyi görselleştirmeyi sunar (250). Ancak, fasiyal sinirin tanımlanmasında geleneksel T1 ve T2 ağırlıklı görüntülerin rolü tartışmalıdır ve bu siniri daha iyi tanımlayan çeşitli sekanslar geliştirilmiştir (251). Bu sekanslar, siniri daha iyi tanımlayan, uzaysal çözünürlüğü ve sinyal-gürültü oranını artıran görüntüler sunar (250, 252).

MRG, ayrıca parotid şişliklerini taklit eden durumların değerlendirilmesinde de faydalıdır. Örneğin, çiğneme kaslarının hipertrofisi nedeniyle görülen belirgin diffüz parotid şişliklerini değerlendirebilir. Ancak MRG'nin sınırlı erişilebilirliği, yüksek maliyeti ve uzun çekim süresi gibi dezavantajları vardır. Belirli kalp pilleri veya metal implantları olan hastalar MRG çekilemez ve klostrofobik olan hastalar tarayıcının kapalı alanını tolere etmekte zorlanırlar (48).

BT, MRG'den daha ucuz olduđu ve daha yaygın olarak bulunabilmesinden dolayı tükürük bezi incelemelerinde sıklıkla kullanılır. Kontrastsız BT, tükürük bezi veya kanaldaki küçük taşların tanımlanmasında faydalıdır ve malign lezyonların neden olduđu kemik erozyonunu aramak için tercih edilen bir tekniktir. Kontrastlı BT, tükürük bezlerinin malign hastalıklarının evrelemesinde kullanılır. MRG'nin kontrendike olduđu durumlarda, derin lobun değerlendirilmesi ve farenks ile boyun lenfadenopatilerinin değerlendirilmesinde kullanışlıdır. Ancak, yüksek radyasyon dozu nedeniyle kullanımı mümkün olduğunca sınırlandırılmalıdır. (51).

Direkt radyografilerin, tükürük bezlerinin incelenmesi konusundaki klinik değeri sınırlıdır. Sadece sialolitiazis veya tümörün komşu mandibulayı etkilediğini gösterebilir. Sialografi, Stenon veya Wharton kanallarına suda çözünebilen kontrast madde enjeksiyonu yapılarak kanal anatomisini, sialolitleri veya darlıkları belirlemek için kullanılır. Dijital subtraksiyon sialografisi, taş veya kanal darlığı şüphesi olan durumlarda yardımcıdır. Dijital subtraksiyon anjiyografisinde olduğu gibi, kontrast madde enjeksiyonundan önce alınan görüntü, enjeksiyondan sonra alınan görüntüden çıkarılarak mükemmel kontrast çözünürlüğü elde edilir ve küçük taşların tespit edilmesini sağlar. Sialogog verildikten sonra işlevsel bilgiler de elde edilebilir. Tekniğin temel zayıflıkları, invaziv olması, kontrast madde ve iyonize radyasyon kullanımı gerektirmesi ve yüksek teknik başarısızlık oranına sahip olmasıdır (48).

MR sialografî, tükürük bezi kanalı hastalıklarının görüntülenmesi için alternatif bir teknik olarak önerilmiştir. MRG, sialolit kanal sistemi üzerindeki etkisini görselleştirmeye olanak tanır. Kronik sialadenit ile ilişkili ağırlı bez vakalarında, BT veya konvansiyonel radyografide sialolit görülmediğinde, kanal sistemindeki düzensizlik ağırlı bezin nedenine dair ipuçları verebilir. Tükürük kanal sisteminin yüksek kaliteli görüntüleri ince kesitli, T2 ağırlıklı görüntülerle elde edilebilmesine rağmen, bezin içindeki ve büyük kanal sistemindeki küçük taşlar, kalsifiye taşla ilişkili sinyal boşluğu nedeniyle gözden kaçabilir. Bu nedenle bu teknik henüz tam olarak yerleşmiş değildir (253, 254).

Nükleer tıp, tükürük bezi fonksiyonunu incelemek için kullanılabilir. PET şu anda iyi huylu ve kötü huylu tükürük bezi tümörlerini güvenilir bir şekilde ayırt edememektedir, bu da klinik kullanımını sınırlamaktadır. Ayrıca pahalıdır ve yapılması uzun zaman alır. PET ve nükleer sintigrafi, majör bezlerin görüntülenmesi için rutin olarak kullanılmaz,

ancak tükürük bezi sintigrafisi ve florodeoksiglukoz (FDG) PET kombinasyonu, tanısal olmayan iğne aspirasyonundan ziyade çeşitli parotis bezi tümörlerinin ayırt edilmesi için daha iyi bir yaklaşım olabilir. PET aynı zamanda başka nedenlerle yapılırken tesadüfi bulguları ortaya çıkarabilmesi açısından da faydalıdır (255).

USG, parotis ve submandibular bezlerin yüzeysel kitlelerinin değerlendirilmesinde faydalı bir tekniktir ve giderek tükürük bezlerinin ilk değerlendirmesinde tercih edilen yöntem haline gelmektedir. Ucuzdur, yaygın olarak bulunur ve güvenlidir. Ayrıca BT ve MRG kadar hassas bir şekilde yüzeysel tükürük bezi lezyonlarını tanımlamak için kullanılabilir. Vakaların %90'ında malign lezyonları benign olanlardan doğru bir şekilde ayırt edebilir, bez içi kitleleri bez dışı kitlelerden %98 doğrulukla ayırt edebilir ve klinik bir kitle şüphesini doğrulayabilir. Neoplazmalar genellikle normal glandüler dokuya göre hipoekoiktir ve USG'nin majör tükürük bezi lezyonlarının %95'ini tamamen tanımladığı bildirilmiştir (109, 256-258).

USG, fasiyal siniri doğrudan görselleştiremez, ancak parotis içindeki intraglandüler damarların doğru bir şekilde tanımlanmasıyla konumunu gösterebilir ve bu nedenle lezyonların yüzeysel veya derin lob olup olmadığını gösterebilir. Yüzeysel lezyonlar, özellikle yüzeysel parotis ve submandibular bezde, USG kılavuzluğunda core biyopsi veya ince iğne aspirasyon biyopsisine uygundur. Yüksek frekanslı USG, radyasyona maruz kalmadan üstün çözünürlük ve doku karakterizasyonu sunar. Kompleks kitlelerin solid bileşenlerinin incelenmesine olanak tanıyarak tanısal verimliliği artırırken, çevre yapıların radyasyondan dolayı hasar görmesini engeller. Ayrıca, birçok merkezde sialolit ve apselerin değerlendirilmesinde birincil görüntüleme yöntemi olarak tercih edilmektedir (109, 256, 257).

Sınırlamaları arasında derin parotis kitlelerini (mandibula tarafından gizlendikleri için), parafaringeal yayılımı, retrofaringeal ve derin boyun adenopatisini ve intrakraniyal veya kafa tabanı kitlelerinin boyutunu değerlendirememesi yer alır. Bu nedenle, bir lezyonun lokal olarak invaziv olup olmadığını, büyük tümörlerin boyutunu göstermek veya bir lezyonun malign olma olasılığını değerlendirmek için daha fazla görüntüleme seçimine rehberlik eder (48).

Bu tez çalışmasında non-invaziv olması, kolay ulaşılabilir olması ve tükürük bezi görüntülemesindeki avantajlarından dolayı USG seçildi.

Literatürde SS şiddetini analiz etme ve teşhisine yardımcı olma amaçlı çeşitli skorlama sistemleri mevcuttur.

Cornec ve ark. 2013 yılında yaptıkları çalışmada, yeni bir skorlama sistemi oluşturarak SS şiddetini değerlendirme ve teşhisine yardımcı olmayı amaçlamıştır. Bu skorlama sistemi, mevcut AECG (Amerika-Avrupa Konsensüs Grubu) kriterlerine tükürük bezi USG bulgularını dahil ederek daha yüksek bir duyarlılık elde etmeyi ve böylece daha fazla Primer Sjögren Sendromu (pSS) hastasının erken teşhisine olanak sağlamayı hedeflemiştir. Çalışma sonuçları, yeni skorlama sisteminin mevcut AECG kriterlerine göre daha yüksek duyarlılığa sahip olduğunu ve daha fazla pSS hastasını tespit edebileceğini göstermiştir (9).

Delli ve ark. 2015 yılında USG'nin SS tanısındaki rolünü inceleyen bir meta-analiz sunmuşlardır. USG'nin, SS'de tükürük bezi tutulumunu değerlendirmek için invaziv olmayan, düşük maliyetli bir yöntem olduğunu ve tanıda %69 duyarlılık ve %92 özgüllük gibi iyi tanısal özelliklere sahip olduğunu göstermişlerdir. Yazarlar, USG'nin SS tanısında potansiyel bir araç olduğunu ancak dahil edilen çalışmalarda bazı metodolojik sorunlar nedeniyle sonuçların dikkatli yorumlanması gerektiğini belirtmişlerdir. Delli ve ark. 2018 yılında yaptıkları çalışmada ise klinik olarak pSS şüphesi olan 80 hastanın ultrasonografik değerlendirmesinde ekojenite, parankimal homojenite, hipoekoik alanların varlığı, hiperekoik yansımalar ve posterior bez sınırının netliği gibi ultrasonografik değişkenleri kullanarak USG'nin pSS değerlendirmesinde güvenilir bir yöntem olduğunu, ancak özellikle yüksek skorlu hastalarda gözlemciler arası farklılıklar olabileceğini vurgulamışlardır (259, 260).

Hocevar ve ark. ekojenite, homojenite, hipoekojenik alanların sayısı, hiperekojenik yansımalar ve tükürük bezinin sınırlarının netliği olmak üzere beş USG parametresi değerlendirdikleri çalışmada sağ ve sol; parotis ve submandibular bezler olmak üzere 4 bezin nihai skorlarını toplamış ve bireylere 0 ile 48 arasında bir skor tayin etmişlerdir. Sonuç olarak beş USG parametresinin tamamının, pSS ile anlamlı derecede ilişkili olduğu ve pSS'li hastaların, pSS tanısı konmayanlara göre anlamlı derecede daha yüksek USG skorlarına sahip olduklarını belirtmişlerdir (6). Milic ve ark. 2009 yılında aynı skorlama sistemiyle yaptıkları çalışmada USG'nin tanısal doğruluğuyla tükürük bezi sintigrafisi ve minör tükürük bezi biyopsisinin tanısal doğruluğunu kıyaslamış,

ROC eğrisi analizi ile USG'nin diğer tanı yöntemlerine göre daha iyi performans gösterdiğini ifade etmişlerdir (58).

Salaffi ve ark. tarafından geliştirilen 0-16 arasındaki USG skorlama sistemi, her iki submandibular ve parotis bezlerinin durumunu değerlendirmek için kullanılmıştır. Sistem, şu beş USG parametresine dayanmaktadır; parankimal homojenite, ekojenite, bez boyutu, posterior bez sınırlarının netliği, hipoekoik alanların varlığı. ROC eğrisi analizi ile USG'nin sialografi ve sintigrafiye göre daha iyi performans gösterdiği belirlenmiştir (8).

Fana ve ark. SS şüphesi olan hastalarda tükürük bezlerinin değerlendirilmesinde OMERACT USG skorlama sisteminin kullanımını ve etkinliğini incelemiştir. Bu sistem, tükürük bezlerindeki USG bulgularını 0'dan 3'e kadar derecelendirir. 0 normal bez yapısını gösterirken 3 ciddi anomaliye işaret eder. Bu skorlama sistemi SS tanısı için iyi bir duyarlılık ve mükemmel bir özgüllük göstermiştir (261). Jousse-Joulin ve ark.'nın çalışmasında yine OMERACT USG skorlama sistemi kullanılmış; 25 uzman, 199 video klipteki tükürük bezi görüntülerini değerlendirmiştir. Sonuçlar, bu yeni skorlama sisteminin hem bireysel değerlendirmelerde hem de farklı değerlendiriciler arasında yüksek derecede güvenilir olduğunu göstermiştir. Özellikle, parotis bezlerinin değerlendirilmesinde güvenilirlik daha yüksek bulunmuştur (262). OMERACT skorlama sistemi ile yapılan bir diğer çalışma USG görüntülerinin pSS tanısı için yüksek duyarlılık ve özgüllük sağladığını ve yüksek tanısal uygulanabilirlik gösterdiğini ortaya koymuştur. Ayrıca, USG'nin hastalık şiddetini ve tedavi etkinliğini belirlemede de klinik değere sahip olabileceği sonucuna varılmıştır (263).

Wernicke ve ark. tarafından 2007 yılında yapılan çalışma primer ve sekonder SS tanısında majör tükürük bezlerinin USG görüntülerinin tanısal değerini doğrulamayı amaçlamıştır. USG ile majör tükürük bezlerinin boyutları ve parankimal ekojeniteleri değerlendirilmiştir. Çalışma sonucunda, majör tükürük bezlerinin parankimal heterojenitesinin ultrasonografik tespiti ve submandibular bezlerin hacminin azalmasının gözlenmesinin, primer ve sekonder SS tanısı için yüksek özgüllük sağladığı belirtilmiştir. Bu veriler, majör tükürük bezlerinin USG'sinin, primer ve sekonder SS tanısı için yüksek tanısal değere sahip, invaziv olmayan bir görüntüleme yöntemi olduğunu göstermiştir (264).

Theander ve ark. tarafından yapılan çalışma, primer SS hastalarında, tükürük bezlerinin ultrasonografik değerlendirmesinin tanısal değerini basitleştirilmiş bir skrolama sistemi kullanarak incelemiştir. Bu sisteme göre tükürük bezlerindeki parankimal homojenite 0'dan 3'e kadar derecelendirilmiş; 0 ve 1 normal veya spesifik olmayan bulguları, 2 ve 3 ise pSS'ye özgü bulguları göstermiştir. Sonuç olarak bu basitleştirilmiş bir skrolama sisteminin pSS için yüksek özgüllüğe sahip olduğunu saptamışlardır (265).

Bu sınıflandırmaların esas kullanım alanları SS hastaları olsa da tükürük bezini etkileyen diğer hastalıklarda ve sağlıklı bireylerde tükürük bezinin sonografik parametrelerinin incelenmesinde kullanılmıştır. Hafez ve ark.'nın yaptığı çalışma sistemik skleroz (SSc) hastalarında majör tükürük bezlerindeki ultrasonografik değişiklikleri ve bu değişikliklerin farklı hastalık belirtileriyle ilişkisini incelemeyi amaçlamıştır. Toplam parotis ve submandibular gri skala USG skorlarının, SSc'ye yatkınlık ile anlamlı ilişki gösterdiği sonucuna varmışlardır (266). Aslan Öztürk ve ark.'nın çalışması diyabet hastalarında submandibular ve parotis tükürük bezlerinin B-mod USG, shear wave elastografi (SWE) ve renkli Doppler USG ile değerlendirilmesini amaçlamıştır. Çalışma sonucuna göre Tip 1 DM, tip 2 DM ve kontrol grupları arasında sağ submandibular bezin ekojenitesi, sağ parotis bezin ekojenitesi, sınır özellikleri, parankimal homojenlik ve renkli Doppler özellikleri açısından istatistiksel olarak anlamlı fark gözlenmiştir (267). Kıranatlı ve ark. yaptıkları çalışmada multipl skleroz (MS) hastalarında majör tükürük bezlerinin homojenliğini USG kullanarak incelemeyi, DMFT indekslerini değerlendirmeyi, istirahat halindeki tükürük akış hızlarını ölçmeyi ve bu değerleri sağlıklı bireylerle karşılaştırmayı amaçlamıştır. Sonuçlar, MS hasta grubunda parotis bezlerinin kontrol grubuna göre USG'de daha fazla heterojenlik gösterdiğini ve iki grup arasında istatistiksel olarak anlamlı bir fark olduğunu ortaya koymuştur (268).

Görgün ve ark. sağlıklı bireylerde yaş ve cinsiyete bağlı olarak tükürük bezlerinde oluşabilecek ultrasonografik değişiklikleri incelemeyi amaçlamıştır. Sonuç olarak, yaşla birlikte submandibular ve parotis bezlerinin homojenliği bozulmuş ve daha heterojen hale gelmiştir. Ayrıca, submandibular ve parotis bezlerinin sınırlarının netliğinin yaş ile azaldığı tespit edilmiştir (269).

Bu çalışmalar, yalnızca SS gibi primer tükürük bezi hastalıklarının değil, diğer hastalıkların ve yaşın da tükürük bezlerinde belirgin değişikliklere yol açabileceğini

ortaya koymaktadır. Bu bağlamda, tükürük bezlerinin sonografik parametrelerinin değerlendirilmesi, hastalık süreçlerinin takibi ve tükürük bezinde meydana gelen değişikliklerin anlaşılması açısından büyük önem taşımaktadır. İlgili bulgular bu parametrelerin tanısal süreçlerde değerli bir araç olabileceğini göstermektedir.

Çalışmamızda submandibular tükürük bezlerinin sonografik parametrelerini sınıflandırırken, Hocevar sınıflamasını temel alıp YZ uygulamalarına uygun olacak şekilde modifiye ettik. Bunun nedeni ilgili sınıflandırmanın daha ayrıntılı değerlendirmeye olanak tanınmasıdır. Bu sınıflandırmaya ek olarak vaskülarizasyon incelemesini de çalışmamıza ilave ettik.

YZ teriminin literatüre girmesinin üzerinden 60 yıldan fazla zaman geçmiş olsa da uygulamaları son birkaç on yılda büyük bir sıçrayış kaydetmiştir. Metin yazımından fotoğraf ve video düzenlemelerine, sohbet botlarından tıp alanına kadar günlük hayatta sıkça karşımıza çıkmaya başlamıştır (270, 271).

Diş hekimliği alanı da bu gelişmelerden payını almış özellikle son yıllarda YZ çalışmalarının sayısı hızla artmıştır. Bu çalışmaların çoğu tıbbi görüntülerin değerlendirilmesiyle hayata geçirilmiştir. Bu görüntüler çeşitli tekniklerle değerlendirilebilir (272). Bunlar algılama, segmentasyon ve sınıflandırma olarak çeşitlendirilebilir. Algılama görevi, ilgili nesnenin görüntülerdeki konumunu belirlemeyi amaçlar. Nesne algılama algoritmalarının etiketli nesneyi içeren dikdörtgen sınırlayıcı kutulara sahip bölge tahminleri oluşturmakla başlar, ardından görüntü özelliklerini hesaplar (272). Bunlara örnek olarak diş çürükleri, restorasyonlar ve süt dişi tespiti verilebilir (188, 214, 273).

Segmentasyon görevi, görüntülerdeki ilgili nesnenin konturunu belirlenmesini amaçlamaktadır. 2D ve 3D radyografik görüntülerde nesne segmentasyonu, ilgi alanındaki her bir pikselin veya vokselin analiz edilmesi ve bunların farklı sınıflara atanması prensibine dayanmaktadır. Segmentasyon görevleri için genellikle DÖ tabanlı mimariler kullanılarak özelleştirilmiş YZ algoritmaları geliştirilmektedir (274). Bu yöntemler, özellikle diş, alveolar kemik ve lezyonların segmentasyonunda etkin bir şekilde uygulanmaktadır (275, 276).

Sınıflandırma görevi, görüntüleri önceden belirlenmiş kategorilere ayırmayı hedefler. Bu süreç, farklı nesnelerden çıkarılan özelliklerin analiz edilmesi ve aralarındaki

farkların değerlendirilmesi ile gerçekleştirilir (272). Buna implant sınıflaması örnek verilebilir (277).

Diş hekimliğinde YZ alanındaki çalışmaların önemli bir kısmı KIBT, panoramik radyografi ve intraoral radyografiler üzerine yapılan çalışmalar olsa da baş ve boyun yumuşak doku incelemelerinde USG'nin kullanımı yaygınlaştıkça, bu alandaki YZ tabanlı araştırmaların sayısı da giderek artmaktadır (278). USG görüntülerinde YZ çalışmalarına örnek olarak çiğneme kaslarının segmentasyonu, periodontal dokuların segmentasyonu, mine sement birleşiminin tespiti gibi çalışmalar verilebilir (279-281).

Literatürde MRG (282, 283) ve BT (284) görüntülerinde olduğu gibi USG görüntüleri üzerinde de tükürük bezlerinin YZ teknikleriyle incelendiği birçok çalışma mevcuttur (284-298).

Vukicevic ve ark. çalışmalarında pSS'den etkilenen tükürük bezlerinin USG görüntülerini DÖ yöntemleriyle segmente eden bir çalışma yapmışlardır. SS, tükürük bezlerinde çeşitli anormalliklere yol açan kronik bir otoimmün hastalıktır. Tükürük bezi USG'si bu hastalığın teşhisinde yaygın olarak kullanılan bir yöntem olmasına rağmen, yorumlama sırasında gözlemciler arasında düşük güvenilirlik nedeniyle tanı koyma sürecinde sınırlamalar bulunmaktadır. Bu soruna çözüm getirmek amacıyla, araştırma ekibi DÖ'ye dayalı dört farklı mimariyi değerlendirmiştir. Çalışma, Avrupa'daki çeşitli kliniklerden elde edilen 1184 etiketli USG görüntüsünden oluşan bir veri kümesi üzerinde gerçekleştirilmiştir. Sonuçlar, FCN-DenseNet modelinin diğer modellerden daha üstün performans gösterdiğini ortaya koymuştur. FCN-DenseNet, %85 doğruluk oranı ile hem hız hem de doğruluk açısından en iyi sonucu vermiştir. Modelin performansı, uzman klinisyenlerin gözlemci içi uyumundan daha iyi olup, saniyede 24.5 kare işleme hızıyla klinik uygulamalar için uygun bir çözüm olarak öne çıkmıştır (287). Bizim çalışmamızda, submandibular tükürük bezlerinin segmentasyonu YOLOv8 modeli ile gerçekleştirilmiş olup, model %100 doğruluk oranı ile üstün bir performans sergilemiştir. Çalışmamızda elde edilen %100 doğruluk oranının bir olası nedeni, YOLOv8 modelinin sağladığı teknik üstünlüklerdir. YOLOv8, daha güncel ve optimize edilmiş bir DÖ modeli olup, önceki mimarilere kıyasla daha hızlı ve daha doğru nesne tespiti yapma kapasitesine sahiptir. Bu model, daha az parametre kullanarak yüksek performans sergilemektedir. YOLOv8'in bu teknik üstünlükleri, segmentasyon işlemlerini daha verimli hale getirerek sonuçların doğruluğunu artırmış olabilir. Bunun

yanı sıra, çalışmamızda normal submandibular tükürük bezlerinin segmentasyonu yapılırken, Vukicevic ve ark.'nın çalışmasında pSS'den etkilenen tükürük bezleri incelenmiştir. Normal bezlerin ultrasonografik yapıları daha belirgin ve homojen olduğundan segmentasyon işlemi daha kolaydır. Buna karşılık, pSS'den etkilenen bezlerdeki patolojik değişiklikler, segmentasyon sürecini zorlaştırmakta ve daha düşük doğruluk oranlarına neden olabilmektedir. Bu yapısal farklılıklar, çalışmamızdaki yüksek başarı oranının bir diğer açıklaması olabilir.

Geng ve ark. çalışmalarında DÖ tabanlı bir yaklaşımı kullanarak pSS teşhisinde tükürük bezi USG görüntülerinin değerlendirilmesini araştırmışlardır. Çalışmada, 2021 ve 2022 yılları arasında bir merkezden elde edilen 137 hastaya ait 1133 USG görüntüsü incelenmiştir. Hastalardan 61'ine pSS teşhisi konulmuşken, 76 hasta SS olmayan kontrol grubunu oluşturmuştur. Görüntüler, eğitim, doğrulama ve test setlerine ayrılarak DÖ modeli olan ResNet mimarisi kullanılmıştır. Sonuçlar, DÖ tabanlı USG görüntü değerlendirmesinin, uzmanlar tarafından yapılan incelemeye kıyasla %86.9 özgüllük ile daha iyi performans gösterdiğini, duyarlılığın ise benzer olduğunu (%59.4) ortaya koymuştur. Ayrıca, ROC eğrisinden hesaplanan AUC değerini DÖ modelinde 0.800, operatör temelli sistemde ise 0.775 olarak hesaplanmıştır. Araştırma ekibi, DÖ tabanlı tükürük bezi USG görüntü değerlendirmesinin, pSS tanısında uzman değerlendirmesi ile karşılaştırılabilir bir doğruluğa sahip olduğunu ve bu yöntemin mevcut tanı yöntemlerine destek olabilecek objektif ve gelecek vaat eden bir araç olduğunu vurgulamışlardır (290).

Wei ve ark. çalışmalarında tükürük bezi tümörlerinin benign ve malign ayrımını DÖ destekli bir modelle, USG görüntülerinin otomatik segmentasyonu yoluyla yapmayı amaçlamışlardır. Toplamda 582 hastanın verileri, dört merkezden retrospektif olarak toplanmış ve analiz edilmiştir. Çalışma sonuçlarına göre ResNet18 modeli, benign ve malign tümörlerin ayrımında %76.5 doğruluk değeriyle en yüksek tahmin performansını sergilemiş ve model yardımıyla radyologların doğru tanı koyma oranı artmıştır (285).

Liao ve ark. tükürük bezi tümörlerinin ayırt edilmesinde USG görüntülerini MÖ kullanarak analiz etmişlerdir. Çalışmada, tükürük bezi tümörlerine sahip 122 hasta incelenmiş ve benign ve malign tümörler arasında ayırım yapabilmek için Gri Düzey Eş Oluşum Matrisi (GLCM) doku özellikleri kullanılmıştır. MÖ modelleri olan KNN, Naïve Bayes, Lojistik Regresyon, YSA ve Destek Vektör Makineleri (SVM) ile bu doku

özelliklerinin tanısal performansı değerlendirilmiştir. Çalışma bulgularına göre altı GLCM doku özelliği benign ve malign tümörler arasında önemli farklar göstermiştir. Naïve Bayes modeli %94,3'lük doğruluk oranıyla en yüksek tanısal başarıyı göstermiştir. Çalışma sonuçları, USG doku analizinin MÖ ile birleştirilerek, tükürük bezi tümörlerinin ayırt edilmesinde objektif ve değerli bir araç olma potansiyeline sahip olduğunu göstermektedir. Bu çalışma, gelecekte daha fazla veri ile doğrulama gereksinimi olan bir ön fizibilite çalışması olarak değerlendirilmektedir (293).

Kise ve ark. yaptıkları çalışmada, SS'nin USG görüntülerini kullanarak DÖ sistemlerinin tanısal performansını araştırmışlardır. Çalışma kapsamında, SS tanısı almış 100 hasta ve SS olmayan ancak ağız kuruluğu yaşayan 100 hasta incelenmiştir. Amaç, DÖ sisteminin tanısal performansını deneyimsiz radyologlarla karşılaştırmaktır. Çalışma bulgularına göre parotis bezleri için DÖ sisteminin doğruluğu %89,5, duyarlılığı %90, özgüllüğü %89 olarak bulunmuştur. Submandibular bezlerde ise DÖ sistemi %84 doğruluk, %81 duyarlılık ve %87 özgüllük göstermiştir. Deneyimsiz radyologların sonuçları ise parotis bezi için %76.7 doğruluk, %67 duyarlılık, %86,3 özgüllük ve submandibular bez için %72 doğruluk, %78 duyarlılık, %66 özgüllük olarak belirlenmiştir. Sonuç olarak, DÖ sistemi, deneyimsiz radyologlara kıyasla SS tanısında daha yüksek bir başarı göstermiştir. Bu da DÖ'nün klinik karar destek sistemlerinde yararlı olabileceğini ortaya koymaktadır (294).

Tu ve ark. DÖ ve USG'yi birleştirerek tükürük bezi tümörlerinin benign veya malign olarak sınıflandırılmasını amaçlayan bir çalışma sunmaktadır. Çalışmada, 638 hastadan alınan ultrason görüntüleri kullanılarak bir DÖ modeli geliştirilmiş ve modelin doğruluğu test edilmiştir. İlk aşamada, sadece DÖ modeli %91.9 doğruluk oranı elde etmiştir. İkinci aşamada ise, KNN gibi MÖ algoritmaları eklenmiş ve doğruluk oranı %93.5'e, duyarlılık %100'e, özgüllük ise %87'ye yükselmiştir. Bu modelin doğruluğu, MRG ve BT gibi diğer görüntüleme yöntemleriyle karşılaştırılabilir seviyede bulunmuştur. Sonuç olarak, bu çalışma, USG görüntülerini kullanarak DÖ teknikleriyle tükürük bezi tümörlerini sınıflandırmanın etkili olabileceğini ve klinik uygulamalarda önemli bir yardımcı araç olarak kullanılabileceğini göstermektedir (288).

Wang ve ark.'nın çalışması parotis bezi tümörlerinin benign ve malign olup olmadığını ayırt etmek için DÖ tabanlı USG sistemlerinin tanısal performansını incelemektedir. Çalışmada, 2014 ile 2020 yılları arasında 251 hasta üzerinde gerçekleştirilen USG

görüntüleri ve histopatolojik bulgular analiz edilmiştir. DÖ modelleri ile yapılan analizler, %77-81 doğruluk oranı ve 0.80-0.82 AUC değerleri göstermiştir. Bu modeller, deneyimsiz radyologların tanısal doğruluğunu aşmış; ancak deneyimli radyologlarla karşılaştırıldığında anlamlı bir fark bulunmamıştır. EfficientNetB3 modeli, %80 doğruluk, %77 duyarlılık ve 0.82 AUC ile en iyi performansı göstermiştir. Bu bulgular, DÖ sistemlerinin, özellikle deneyimsiz radyologlar için tanı sürecinde değerli bir destek sağlayabileceğini göstermektedir. Sonuç olarak, DÖ sistemlerinin parotis bezi tümörlerinin tanısında kullanılabilir olduğu ve USG ile benign ve malign tümörleri ayırt etmede etkili sonuçlar verdiği görülmüştür (296).

Zhang ve ark. USG görüntüleri ve klinik veriler kullanarak DÖ modeli aracılığıyla benign ve malign parotis bezi tümörlerini ayırt etmeyi amaçlayan bir çalışma sunmuşlardır. Çalışma kapsamında, 266 hastadan alınan veriler kullanılarak çeşitli DÖ modelleri test edilmiştir. Çalışmada SqueezeNet, ResNet101, VGG16 ve MobileNetV2 gibi DÖ mimarileri değerlendirilmiştir. Bu modeller, USG görüntülerini kullanarak benign ve malign tümörleri sınıflandırmak için eğitilmiştir. SqueezeNet, %92.5 doğruluk, %96.6 duyarlılık ve %88.3 özgüllük ile diğer modellere kıyasla daha iyi performans göstermiştir. DÖ modeli, radyologların klinik verilerle birlikte yaptığı değerlendirmelerden daha yüksek bir tanısal doğruluk elde etmiştir. Modelin AUC değeri 0.9583, duyarlılığı %97.2 ve özgüllüğü %94.4 olarak belirlenmiştir. Radyologların performansı ile kıyaslandığında, DÖ modeli tüm radyologlardan daha iyi sonuçlar vermiştir. Sonuç olarak, DÖ tabanlı USG tanı modelinin, parotis bezi tümörlerinin benign ve malign formlarını ayırt etmek için yüksek performans sergilediği ve klinik karar süreçlerine değerli bir katkı sağlayabileceği sonucuna varılmıştır (297).

He ve ark.'nın çalışması, pleomorfik adenom (PMA) ve Warthin tümörlerini (WT) ayırt etmek için USG tabanlı bir MÖ modelinin (USEML) geliştirilmesini ve değerlendirilmesini ele almaktadır. Bu tümörlerin preoperatif sınıflandırılması, uygun tedavi stratejilerini belirlemek için kritik bir öneme sahiptir. Çalışmada, klinik veriler, USG görüntü özellikleri ve radyomik veriler birleştirilerek bir MÖ modeli geliştirilmiştir. USEML modeli, AUC değeri 0.891 ile en yüksek tanısal performansı sergilemiştir. Bu sonuç, klinik model (AUC 0.814) ve USG modeli (AUC 0.847) ile karşılaştırıldığında daha yüksektir. USEML modeli, deneyimli doktorların doğrulama setlerinde elde ettiği sonuçları da aşmıştır. Modelin duyarlılığı %89.3, özgüllüğü %87.5 olarak bulunmuştur. Buna karşılık, doktorların duyarlılık ve özgüllük oranları sırasıyla

%75 ve %54.2'dir. USEML modeli, klinik ve USG verilerinin yanı sıra radyomik özellikleri birleştirerek PMA ve WT'nin ayırt edilmesinde başarılı sonuçlar elde etmiştir. Sonuç olarak modelin, klinikte doktorların tanı doğruluğunu artırabilecek potansiyele sahip olduğu belirtilmiştir (286).

Olivier ve ark.'nın çalışması, Gougerot-Sjögren Sendromu'nun (GSS) teşhisi için MÖ ve DÖ yaklaşımlarını ele almıştır. Çalışmada USG görüntülerinden alınan veriler kullanılarak tükürük bezlerin segmentasyonu ve sınıflandırılması yapılmıştır. İlk aşamada, bezlerin otomatik segmentasyonu gerçekleştirilmiş, ikinci aşamada ise bu segmentasyon sonuçlarına dayalı olarak GSS sınıflandırılması yapılmıştır. Çalışma bulgularına göre DÖ modeli, uzmanlar tarafından yapılan segmentasyon sonuçlarıyla karşılaştırılabilir başarı göstermiştir. GSS teşhisinde en yüksek doğruluğa, modelin iki aşamalı eğitim süreciyle ulaşılmıştır. Bu süreçte, segmentasyon ve sınıflandırma görevleri bir arada eğitilmiştir. Radyomik özelliklerin ve DÖ yöntemlerinin kombinasyonu, tükürük bezlerinin USG görüntüleri üzerinden GSS teşhisinde umut vaat etmektedir. Sonuç olarak, bu çalışma, MÖ ve DÖ tekniklerinin GSS teşhisinde kullanılmasının etkili olabileceğini ve USG görüntüleriyle yapılan segmentasyon ve sınıflandırmanın tıbbi teşhislerde değerli bilgiler sağlayabileceğini ortaya koymaktadır (292).

Vukicevic ve ark. çalışmalarında tükürük bezlerinin USG görüntülerinden pSS teşhisi için radyomik özellikler ve YZ algoritmaları kullanılmıştır. Bu çalışma, uzmanların manuel skorlama sürecine kıyasla daha objektif ve hızlı bir skorlama sağlamak amacıyla gerçekleştirilmiştir. İki merkezde toplanan 600 USG görüntüsü üzerinde, her bir görüntü için 907 histogram tabanlı ve tanımlayıcı istatistiksel özellik çıkarılmıştır. Çalışmada, çeşitli sınıflandırıcı ve regresyon algoritmaları karşılaştırılmış ve çok katmanlı algılayıcı (MLP) algoritması en iyi performansı göstermiştir. MLP, klinik uzmanların ortalama skorunu aşarak ($\kappa = 0.7$) daha yüksek bir güvenilirlik ve tutarlılık sunmuştur. Bulgular, tükürük bezi USG'sinin invaziv olmayan ve etkili bir pSS tanı aracı olarak kabul edilebileceğini göstermektedir (298).

Vukicevic ve ark.'nın bir diğer çalışması pSS olan hastaların tükürük bezlerinin USG görüntülerini DÖ algoritmaları kullanarak otomatik olarak değerlendirmeyi amaçlamıştır. Çalışmada, tükürük bezlerinin USG görüntüleri De Vita ve ark. (299)'nın önerdiği 4 skorlu sistem ile analiz edilerek pSS tanısının desteklenmesi için çeşitli DÖ

algoritmaları ile incelenmiştir. Bu modeller arasında bizim çalışmamızda da kullanılan MobileNetv2, VGG19 ve Inceptionv3 haricinde DenseNet, SqueezeNet ve ResNet modelleri de yer almaktadır. Araştırmanın bulguları, DÖ algoritmalarının pSS'nin tanı ve derecelendirilmesinde klinisyen düzeyinde performans gösterdiğini ortaya koymuştur. Özellikle, MobileNetV2, ResNet ve DenseNet algoritmaları en iyi sonuçları vermiştir. Bu algoritmalar, tükürük bezi USG görüntülerini hızlı bir şekilde işleyerek neredeyse gerçek zamanlı değerlendirme yapabilmektedirler. Bu durum, pSS tanısında bu tür teknolojilerin uygulanabilir olduğunu ve klinik uygulamalarda kullanılarak hastalık tanısının daha güvenilir ve hızlı yapılabileceğini göstermektedir. Çalışmanın sonucunda, DÖ algoritmalarının pSS tanısında invaziv olmayan bir yöntem olarak kullanılma potansiyeli vurgulanmaktadır (289).

Bizim çalışmamız da Vukicevic ve ark.'nın çalışmasına benzer şekilde sonografik parametrelerin DÖ algoritmalarıyla sınıflandırmasını konu almaktadır. Ancak iki çalışma arasında ciddi farklar bulunmaktadır. İlgili çalışma sadece tek sınıflamaya odaklanırken bizim çalışmamız beş farklı parametrenin sınıflamasını yapmıştır. Bu çalışmada en yüksek doğruluğa sahip model %89.5 ile ResNet modeli olmuştur. Bizim çalışmamızda ise marjin ve vaskülarizasyon lokalizasyonu haricinde diğer sınıflamalar %90 üzerinde doğruluk oranı göstermiştir. Bu da parametrelerin ayrı ayrı sınıflamasının daha yüksek doğruluk gösterdiğini ortaya koymuştur. Ayrıca ilgili çalışma sadece pSS hastalarını çalışmaya dahil etmiş olup özellikle belli bir gruba odaklanmıştır. Sunduğumuz çalışmada ise daha kapsayıcı bir çalışma grubu oluşturmak amacıyla tüm hastalar dahil edilmiş; bu sınıflandırmaların sadece SS hastalarında değil tüm hastalar ve hastalıklarda kullanabileceği kanıtlanmıştır.

Zhang ve ark. (297) çalışmalarında DÖ modelinden elde ettikleri ısı haritalarına dayanarak, DÖ modelinin benign ve malign tümörleri etkili bir şekilde ayırmak için marjin bilgilerini kullandığı sonucuna varmışlardır. Ayrıca renkli doppler USG'nin tanı sonuçlarını daha da iyileştirebileceğini vurgulamışlardır. Sunulan çalışmada en başarılı modeller marjin değerlendirilmesi için %74.4, vaskülarizasyon şiddeti ise %100 doğruluk göstermiştir. Bununla birlikte SS'nun da tükürük bezlerinin homojenitesini bozduğu bilinmektedir (259). Çalışmamız submandibular tükürük bezlerinin homojenitelerini %93.6 doğruluk oranıyla ayırmayı başarmıştır. Tüm bu bulgular DÖ algoritmaları kullanılarak yapılan sınıflandırmaların başta malign benign tümör ayırımı

ve SS teşhisi olmak üzere tükürük bezi hastalıklarının teşhisindeki potansiyelini ortaya koymaktadır.

Çalışmamızda, homojenite ve marjin sınıflaması dışında diğer sınıflamalarda en yüksek doğruluk oranını YOLOv8 modeli elde etmiştir. Bu modelin daha güncel olması, yüksek performans göstermesinin olası sebeplerinden biri olarak değerlendirilmektedir. Bununla birlikte, marjin sınıflamasında diğer sınıflamalara kıyasla daha düşük doğruluk oranları gözlemlenmiştir. Bu durumun, marjinlerin görüntünün oransal olarak daha küçük bir bölümünü kapsaması ve bu alanların sınıflandırılmasının zorluğundan kaynaklandığını düşünmekteyiz.

Çalışmamızda her sınıflama için her bir grupta eşit sayıda hasta bulunmamaktadır. Bunun temel nedeni, bazı grupların toplum genelinde daha az yaygın olmasıdır. YZ modelleri, genellikle sayıca fazla olan grupları seçme eğilimindedir. Bu durum, nadir görülen gruplara ait verilerin azlığı nedeniyle, modelin bu gruplarda daha düşük performans göstermesine yol açabilir. Nadir gruplara ait örneklem sayısının artırılması durumunda, modelin doğruluğunun da önemli ölçüde yükselebileceği öngörülmektedir. Bu, çalışmamızın limitasyonları arasında kabul edilebilir. Gelecekteki çalışmalarda, veri sayısının artırılması, her grupta benzer sayıda örneklem kullanılması ve çok merkezli veriler kullanılması önerilebilir. Ayrıca, USG doku analiz bulgularını MÖ algoritmalarına entegre eden ve elde edilen sonuçları hem deneyimli radyologların değerlendirmeleriyle hem de diğer YZ sistemlerinin performansı ile karşılaştırmalı olarak değerlendirilen çalışmalar yapılabilir.

Sonografik parametrelerin YZ ile otomatik sınıflandırılması, klinisyenlere önemli ölçüde zaman kazandırma potansiyeline sahiptir. Ayrıca, raporlama süreçlerinde karar verme aşamalarını hızlandırarak klinik uygulamalarda önemli bir destek aracı olarak kullanılabileceği öngörülmektedir.

6. SONUÇ VE ÖNERİLER

Bu çalışmada, DÖ algoritmalarının submandibular tükürük bezlerinin USG görüntülerinde segmentasyonu ve sonografik parametrelerinin sınıflandırılmasındaki başarısını ölçmeyi amaçladık. Sonuç olarak;

- Submandibular tükürük bezi segmentasyonu için YOLOv8 modeli %100 doğruluk gösterdi.
- Submandibular tükürük bezlerinin ekojenite değerlendirilmesinde %97.6 doğrulukla en başarılı model YOLOv8 olurken, VGG19 ve Xception modelleri %95.7 doğrulukla yüksek başarı gösterdi.
- Homojenite sınıflandırmasında en yüksek doğruluk değerini %93.6 ile MobileNetv2 gösterdi. YOLOv8 modeli ise %91.4 doğruluk göstererek en başarılı ikinci model oldu.
- Sonografik parametreler arasında en düşük sınıflama doğruluğuna sahip olan grup marjin değerlendirmesi oldu. Bu sınıflama için en yüksek doğruluğa sahip iki model %74.4 ile MobileNet ve %72.3 ile YOLOv8 olurken, Xception en düşük doğruluk değerini (%54.2) gösteren model oldu.
- Vaskülarizasyon lokalizasyonlarının değerlendirilmesinde YOLOv8 ve Xception modelleri %89.3 doğruluk oranlarıyla en başarılı modeller olmuştur.
- Vaskülarizasyon şiddeti sınıflamasında ise YOLOv8 %100 gibi çarpıcı bir başarı gösterirken, onu %96.8 doğruluk ile MobileNet takip etmiştir.

Bu çalışma, submandibular tükürük bezlerinin USG görüntülerinde DÖ algoritmalarının segmentasyon ve sonografik parametrelerin sınıflandırılması konusundaki yüksek başarısını ortaya koymuştur. Bu bulguların klinik uygulamaya entegre edilmesiyle karar destek sistemlerinin geliştirilmesi hedeflenmektedir, böylece klinisyenlere tanı ve tedavi süreçlerinde önemli bir destek sağlanabilecektir. Gelecekte daha fazla veri ve nadir gruplar için çeşitlilik sağlanarak model performansının artırılması ve çok merkezli çalışmalarla doğrulama yapılması önerilmektedir.

7.KAYNAKLAR

1. Chibly AM, Aure MH, Patel VN, Hoffman MP. Salivary gland function, development, and regeneration. *Physiological reviews*. 2022;102(3):1495-552.
2. Silvers AR, Som PM. Salivary glands. *Radiologic clinics of north America*. 1998;36(5):941-66.
3. Porcheri C, Mitsiadis TA. Physiology, pathology and regeneration of salivary glands. *Cells*. 2019;8(9):976.
4. Katz P, Hartl DM, Guerre A. Clinical ultrasound of the salivary glands. *Otolaryngologic Clinics of North America*. 2009;42(6):973-1000.
5. Lorenzon M, Spina E, Tulipano Di Franco F, Giovannini I, De Vita S, Zabotti A. Salivary gland ultrasound in primary Sjögren's syndrome: current and future perspectives. *Open Access Rheumatology: Research and Reviews*. 2022:147-60.
6. Hocevar A, Ambrozic A, Rozman B, Kveder T, Tomsic M. Ultrasonographic changes of major salivary glands in primary Sjogren's syndrome. Diagnostic value of a novel scoring system. *Rheumatology*. 2005;44(6):768-72.
7. Martino M, Fodor D, Fresilli D, Guiban O, Rubini A, Cassoni A, et al. Narrative review of multiparametric ultrasound in parotid gland evaluation. *Gland Surgery*. 2020;9(6):2295.
8. Salaffi F, Carotti M, Iagnocco A, Luccioli F, Ramonda R, Sabatini E, et al. Ultrasonography of salivary glands in primary Sjögren's syndrome: a comparison with contrast sialography and scintigraphy. *Rheumatology*. 2008;47(8):1244-9.
9. Cornec D, Jousse-Joulin S, Pers JO, Marhadour T, Cochener B, Boisramé-Gastrin S, et al. Contribution of salivary gland ultrasonography to the diagnosis of Sjögren's syndrome: toward new diagnostic criteria? *Arthritis & Rheumatism*. 2013;65(1):216-25.
10. Carotti M, Ciapetti A, Jousse-Joulin S, Salaffi F. Ultrasonography of the salivary glands: the role of grey-scale and colour/power Doppler. *Clin Exp Rheumatol*. 2014;32(1 Suppl 80):S61-70.
11. Kainz B, Heinrich MP, Makropoulos A, Oppenheimer J, Mandegaran R, Sankar S, et al. Non-invasive diagnosis of deep vein thrombosis from ultrasound imaging with machine learning. *NPJ Digital Medicine*. 2021;4(1):137.
12. Mintz GS, Garcia-Garcia HM, Nicholls SJ, Weissman NJ, Bruining N, Crowe T, et al. Clinical expert consensus document on standards for acquisition, measurement and reporting of intravascular ultrasound regression/progression studies. *Invasive Imaging of Coronary Atherosclerosis*. 2011;295(10.4244).
13. Hamet P, Tremblay J. Artificial intelligence in medicine. *metabolism*. 2017;69:S36-S40.
14. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Medical image analysis*. 2017;42:60-88.
15. Xiao S, Zhang J, Zhu Y, Zhang Z, Cao H, Xie M, et al. Application and progress of artificial intelligence in fetal ultrasound. *Journal of Clinical Medicine*. 2023;12(9):3298.
16. He F, Wang Y, Xiu Y, Zhang Y, Chen L. Artificial intelligence in prenatal ultrasound diagnosis. *Frontiers in medicine*. 2021;8:729978.
17. Bonny T, Al Nassan W, Obaideen K, Al Mallahi MN, Mohammad Y, El-Damanhoury HM. Contemporary role and applications of artificial intelligence in dentistry. *F1000Research*. 2023;12.
18. de Almeida PDV, Gregio A, Machado M, De Lima A, Azevedo LR. Saliva composition and functions: a comprehensive review. *J contemp dent pract*. 2008;9(3):72-80.
19. Ferraris M, Muñoz A. *Erupção Dentária. Histologia e Embriologia Bucodental* 2th ed Rio de Janeiro, Guanabara Koogan. 2006:347-64.
20. Edgar W. Saliva: its secretion, composition and functions. *British dental journal*. 1992;172(8):305-12.

21. Humphrey SP, Williamson RT. A review of saliva: normal composition, flow, and function. *The Journal of prosthetic dentistry*. 2001;85(2):162-9.
22. Washington N, Washington C, Wilson C. *Physiological pharmaceuticals: barriers to drug absorption*: CRC Press; 2000.
23. Tabak LA. A revolution in biomedical assessment: the development of salivary diagnostics. *Journal of Dental Education*. 2001;65(12):1335-9.
24. Tenovuo J, Lagerlöf F. *Saliva*. Thylstrup A, Fejerskov O *Textbook of clinical cariology* 2nd ed Copenhagen: Munksgaard. 1994:713-17.
25. Dawes C. Physiological factors affecting salivary flow rate, oral sugar clearance, and the sensation of dry mouth in man. *Journal of dental research*. 1987;66(2_suppl):648-53.
26. Axelsson P. *Diagnosis and risk prediction of dental caries*. (No Title). 2000.
27. Navazesh M. Methods for collecting saliva. *Annals of the New York Academy of Sciences*. 1993;694(1):72-7.
28. Navazesh M. Salivary gland hypofunction in elderly patients. *Journal of the California Dental Association*. 1994;22(3):62-8.
29. Navazesh M, Christensen C, Brightman V. Clinical criteria for the diagnosis of salivary gland hypofunction. *J Dent Res*. 1992;71(7):1363-9.
30. POLAT SÖ. Tükürük Bezlerine Güncel Bakış: Yeni Bir Organ Tartışması. *Arşiv Kaynak Tarama Dergisi*. 2021;30(2):59-67.
31. Moore KL, Persaud TVN, Torchia MG. *The developing human-e-book: clinically oriented embryology*: Elsevier Health Sciences; 2018.
32. Ellis H. *Anatomy of the salivary glands*. Surgery (Oxford). 2012;30(11):569-72.
33. BORAHAN MO, PEKİNER FN, OKUMUŞ Ö. Tükürük Bezi Hastalıklarında Ultrasonografi Bulguları. *Türkiye Klinikleri Oral and Maxillofacial Radiology-Special Topics*. 2015;1(1):130-5.
34. Granley D, Jakobs J, Kern R. *Anatomy in otolaryngology head and neck surgery*. Mosby Year Book. 1992;56:977-85.
35. Newlands SD. *Head & Neck Surgery-Otolaryngology*: LWW; 2006.
36. Ahmed F, Ehsan-ul-Haque M, Ahmad R, Ahmed I, Kaukab N. FACIAL NERVE: PATTERN OF DISTRIBUTION IN THE PAROTID GLAND. *The Professional Medical Journal*. 2005;12(01):85-90.
37. YILDIRIM D, BOZDEMİR E. Tükürük Bezlerindeki İnflamatuvar Değişikliklerin Teşhisinde Ultrasonografik Muayene. *Türkiye Klinikleri Oral and Maxillofacial Radiology-Special Topics*. 2016;2(3):53-8.
38. Hand AR, Pathmanathan D, Field RB. Morphological features of the minor salivary glands. *Archives of oral biology*. 1999;44:S3-S10.
39. Afzelius P, Nielsen MY, Ewertsen C, Bloch KP. Imaging of the major salivary glands. *Clinical physiology and functional imaging*. 2016;36(1):1-10.
40. Noffke C, Raubenheimer E, Chabikuli N. Radiopacities in soft tissue on dental radiographs: diagnostic considerations: clinical review. *South African Dental Journal*. 2015;70(2):53-7.
41. Osmer JC, Pleasants JE. Distention sialography. *Radiology*. 1966;87(1):116-8.
42. Aoun G, Nasseh I, Berberi A. Evaluation of the oral component of Sjögren's syndrome: An overview. *Journal of International Society of Preventive and Community Dentistry*. 2016;6(4):278-84.
43. Yousem DM, Kraut MA, Chalian AA. Major salivary gland imaging. *Radiology*. 2000;216(1):19-29.
44. Freling N. Imaging of the salivary glands. CT and MRI. *Der Radiologe*. 1994;34(5):264-72.
45. Freling N. MRI of the salivary glands. *Erasmus Course MRI Head & Neck*. 2010:1-5.
46. Oyar O. Magnetik rezonans görüntüleme MRG nin klinik uygulamaları ve endikasyonları. *Harran Üniversitesi Tıp Fakültesi Dergisi*. 2008;5(2):31-40.

47. Moonis G, Patel P, Koshkareva Y, Newman J, Loevner L. Imaging characteristics of recurrent pleomorphic adenoma of the parotid gland. *American Journal of Neuroradiology*. 2007;28(8):1532-6.
48. Burke C, Thomas R, Howlett D. Imaging the major salivary glands. *British Journal of Oral and Maxillofacial Surgery*. 2011;49(4):261-9.
49. Kondo A, Hayakawa Y, Dong J, Honda A. Iterative correction applied to streak artifact reduction in an X-ray computed tomography image of the dento-alveolar region. *Oral radiology*. 2010;26:61-5.
50. Miracle A, Mukherji S. Conebeam CT of the head and neck, part 1: physical principles. *American Journal of Neuroradiology*. 2009;30(6):1088-95.
51. Miracle A, Mukherji S. Conebeam CT of the head and neck, part 2: clinical applications. *American journal of neuroradiology*. 2009;30(7):1285-92.
52. Heo M-S, Lee S-C, Lee S-S, Choi H-M, Choi S-C, Park T-W. Quantitative analysis of normal major salivary glands using computed tomography. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*. 2001;92(2):240-4.
53. Tenhunen M, Collan J, Kouri M, Kangasmäki A, Heikkonen J, Kairemo K, et al. Scintigraphy in prediction of the salivary gland function after gland-sparing intensity modulated radiation therapy for head and neck cancer. *Radiotherapy and Oncology*. 2008;87(2):260-7.
54. Daniels TE, Powell MR, Sylvester RA, Talal N. An evaluation of salivary scintigraphy in sögren's syndrome. *Arthritis & Rheumatism: Official Journal of the American College of Rheumatology*. 1979;22(8):809-14.
55. Aung W, Murata Y, Ishida R, Takahashi Y, Okada N, Shibuya H. Study of quantitative oral radioactivity in salivary gland scintigraphy and determination of the clinical stage of Sjögren's syndrome. *Journal of nuclear medicine*. 2001;42(1):38-43.
56. Tensing E-K, Nordström DC, Solovieva S, Schauman K, Sippo-Tujunen I, Helve T, et al. Salivary gland scintigraphy in Sjögren's syndrome and patients with sicca symptoms but without Sjögren's syndrome: the psychological profiles and predictors for salivary gland dysfunction. *Annals of the rheumatic diseases*. 2003;62(10):964-8.
57. Henriksen AM, Nossent HC. Quantitative salivary gland scintigraphy can distinguish patients with primary Sjögren's syndrome during the evaluation of sicca symptoms. *Clinical rheumatology*. 2007;26:1837-41.
58. Milic VD, Petrovic RR, Boricic IV, Marinkovic-Eric J, Radunovic GL, Jeremic PD, et al. Diagnostic value of salivary gland ultrasonographic scoring system in primary Sjögren's syndrome: a comparison with scintigraphy and biopsy. *The Journal of rheumatology*. 2009;36(7):1495-500.
59. Vinagre F, Santos M, Prata A, da Silva JC, Santos A. Assessment of salivary gland function in Sjögren's syndrome: the role of salivary gland scintigraphy. *Autoimmunity reviews*. 2009;8(8):672-6.
60. Keyes Jr JW, Harkness BA, Greven KM, Williams 3rd D, Watson Jr NE, McGuirt WF. Salivary gland tumors: pretherapy evaluation with PET. *Radiology*. 1994;192(1):99-102.
61. Park HL, Yoo IR, Lee N, Yoon H, Choi EK, Choi HS, et al. The value of F-18 FDG PET for planning treatment and detecting recurrence in malignant salivary gland tumors: comparison with conventional imaging studies. *Nuclear medicine and molecular imaging*. 2013;47:242-8.
62. Sharma P, Jain TK, Singh H, Suman SK, Faizi NA, Kumar R, et al. Utility of 18F-FDG PET-CT in staging and restaging of patients with malignant salivary gland tumours: A single-institutional experience. *Nuclear Medicine Communications*. 2013;34(3):211-9.
63. Hertzberg BS, Middleton WD. *Ultrasound: the requisites*: Elsevier Health Sciences; 2015.
64. Rama Mohan K, Koteswara Rao N, Leela Krishna G, Santosh Kumar V, Ranganath N, Vijaya Lakshmi U. Role of Ultrasonography in Oral and Maxillofacial Surgery: A Review of Literature. *Journal of Maxillofacial and Oral Surgery*. 2015;14(2):162-70.

65. El-Rasheedy AE-II, Abdalla AMAR, Hassanein SA-h, Hafez TARA, Aboel-naga HA-r. The role of ultrasound in evaluating salivary glands swellings. *The Egyptian Journal of Otolaryngology*. 2021;37(1):101.
66. Ding A, Lv H, Cao J, Wang X, Xiong P. Ultrasonography characteristics of cystic components in primary salivary gland tumors. *BMC Cancer*. 2023;23(1):833.
67. Yasumoto M, Nakagawa T, Shibuya H, Suzuki S, Satoh T. Ultrasonography of the sublingual space. *Journal of ultrasound in medicine*. 1993;12(12):723-9.
68. Jones JK, Frost DE. Ultrasound as a diagnostic aid in maxillofacial surgery: Report of a case. *Oral surgery, oral medicine, oral pathology*. 1984;57(6):589-94.
69. González-García A, Diniz-Freitas M, Somoza-Martín M, García-García A. Ultrasonic osteotomy in oral surgery and implantology. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*. 2009;108(3):360-7.
70. Aldrich JE. Basic physics of ultrasound imaging. *Critical care medicine*. 2007;35(5):S131-S7.
71. Gandage SG, Kachewar SG. An Imaging Panorama of Salivary Gland Lesions as seen on High Resolution Ultrasound. *Journal of clinical and diagnostic research : JCDR*. 2014;8(10):Rc01-13.
72. Kossoff G. Basic physics and imaging characteristics of ultrasound. *World journal of surgery*. 2000;24(2):134-42.
73. Taşdemir B, Dostbil Z, Sezgin İ. Tükürük bezi sintigrafisinde majör tükürük bezi fonksiyonları hesaplanmasında geri plan düzeltmesinin önemi. *Dicle Medical Journal/Dicle Tıp Dergisi*. 2015;42(4).
74. Harorlu A, Akgül M, Yılmaz B, Bilge O, Dağistan S, Çakur B, et al. Ağız, Diş ve Çene Radyolojisi. 1. baskı İstanbul; Nobel Tıp Kitapevleri Tic. Ltd Şti. 2014:484-500.
75. Abu-Zidan FM, Hefny AF, Corr P. Clinical ultrasound physics. *Journal of emergencies, trauma, and shock*. 2011;4(4):501-3.
76. Oyar O. Boyun ultrasonografisi: Güven & Nobel Kitabevleri; 2000.
77. Masic I, Ridjanovic Z, Pandza H, Masic Z. *Medical informatics: Avicena Sarajevo*; 2010.
78. Carovac A, Smajlovic F, Junuzovic D. Application of ultrasound in medicine. *Acta Informatica Medica*. 2011;19(3):168.
79. Rashid S. The basics of ultrasonography. *Bangladesh Medical Journal*. 2017;46(1):44-7.
80. Mayette M, Mohabir PK. *Ultrasound physics. Point of Care Ultrasound E-book*. 2014:2.
81. Peng C-L, Miethke R-R, Pong S-J, Lin C-T. Investigation of tongue movements during swallowing with M-mode ultrasonography. *Journal of orofacial orthopedics= Fortschritte der Kieferorthopädie: Organ/official journal Deutsche Gesellschaft für Kieferorthopädie*. 2007;68(1):17-25.
82. Galén S, Jost-Brinkmann P-G. B-mode and M-mode Ultrasonography of Tongue Movements during Swallowing. *Journal of Orofacial Orthopedics / Fortschritte der Kieferorthopädie*. 2010;71(2):125-35.
83. Iro H, Zenk J, Bozzato A. *Atlas of head and neck ultrasound: Thieme Stuttgart*; 2013.
84. Kaya T, Adapınar B, Özkan R. *Temel radyoloji tekniği. Nobel Kitabevi, İstanbul*. 1997.
85. Sofferman RA. *Physics and principles of ultrasound. Ultrasound of the Thyroid and Parathyroid Glands: Springer*; 2011. p. 9-19.
86. Bialek EJ, Jakubowski W. Mistakes in ultrasound examination of salivary glands. *Journal of Ultrasonography*. 2016;16(65):191-203.
87. Miloğlu Ö, Aydın E. NAZOLABIAL KİST: KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ, MANYETİK REZONANS VE ULTRASONOGRAFİ BULGULARIYLA DEĞERLENDİRİLEN BİR VAKA RAPORU. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi*. 2021;31(2):271-4.
88. Oyar O, UK G. *Ultrasonografi fiziği. Tıbbi Görüntüleme Fiziği'inde, Ankara: Rekmay Basımevi*. 2003:197-218.
89. Nightingale K, McAleavey S, Trahey G. Shear-wave generation using acoustic radiation force: in vivo and ex vivo results. *Ultrasound in medicine & biology*. 2003;29(12):1715-23.

90. Feldman MK, Katyal S, Blackwood MS. US artifacts. *Radiographics*. 2009;29(4):1179-89.
91. Balleyguier C, Canale S, Hassen WB, Vielh P, Bayou E, Mathieu M, et al. Breast elasticity: principles, technique, results: an update and overview of commercially available software. *European Journal of Radiology*. 2013;82(3):427-34.
92. Fonseca EKUN, Dutenhefner EE, Lange Filho R. Comet-tail artifact in adenomyomatosis. *Abdominal Radiology*. 2018;43(12):3516-7.
93. Shimizu M, Ußmüller J, Hartwein J, Donath K. A comparative study of sonographic and histopathologic findings of tumorous lesions in the parotid gland. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*. 1999;88(6):723-37.
94. Kossoff G. Basic physics and imaging characteristics of ultrasound. *World journal of surgery*. 2000;24(2):134-42.
95. Chan V, Perlas A. Basics of ultrasound imaging. *Atlas of ultrasound-guided procedures in interventional pain management*. 2011:13-9.
96. Bönhof J. Ultrasound Artifacts—Part 1. *Ultraschall in der Medizin-European Journal of Ultrasound*. 2016;37(02):140-56.
97. Sartori S, Tombesi P. Emerging roles for transthoracic ultrasonography in pleuropulmonary pathology. *World journal of radiology*. 2010;2(2):83.
98. McQueen AS, Bhatia KS. Thyroid nodule ultrasound: technical advances and future horizons. *Insights into imaging*. 2015;6:173-88.
99. Chandak R, Degwekar S, Bhowte R, Motwani M, Banode P, Chandak M, et al. An evaluation of efficacy of ultrasonography in the diagnosis of head and neck swellings. *Dentomaxillofacial Radiology*. 2011;40(4):213-21.
100. Milic V, Petrovic R, Boricic I, Radunovic G, Marinkovic-Eric J, Jeremic P, et al. Ultrasonography of major salivary glands could be an alternative tool to sialoscintigraphy in the American–European classification criteria for primary Sjögren's syndrome. *Rheumatology*. 2012;51(6):1081-5.
101. Narang D. Ultrasound in dentistry. *International Journal of Dental Research*. 2022;4(1).
102. Kalinowski M, Heverhagen JT, Rehberg E, Klose KJ, Wagner H-J. Comparative study of MR sialography and digital subtraction sialography for benign salivary gland disorders. *American journal of neuroradiology*. 2002;23(9):1485-92.
103. Sites BD, Brull R, Chan VW, Spence BC, Gallagher J, Beach ML, et al. Artifacts and pitfall errors associated with ultrasound-guided regional anesthesia: Part I: Understanding the basic principles of ultrasound physics and machine operations. *Regional Anesthesia & Pain Medicine*. 2007;32(5):412-8.
104. Alam T, Khattak YJ, Beg M, Raouf A, Azeemuddin M, Khan AA. Diagnostic accuracy of ultrasonography in differentiating benign and malignant thyroid nodules using fine needle aspiration cytology as the reference standard. *Asian Pacific Journal of Cancer Prevention*. 2014;15(22):10039-43.
105. Bialek EJ, Jakubowski W, Zajkowski P, Szopinski KT, Osmolski A. US of the major salivary glands: anatomy and spatial relationships, pathologic conditions, and pitfalls. *Radiographics*. 2006;26(3):745-63.
106. Costache A, Dumitru M, Anghel I, Cergan R, Anghel AG, Sarafoleanu C. Ultrasonographic anatomy of head and neck—a pictorial for the ENT specialist. *Medical Ultrasonography*. 2015;17(1):104-8.
107. Sodhi KS, Bartlett M, Prabhu NK. Role of high resolution ultrasound in parotid lesions in children. *International Journal of Pediatric Otorhinolaryngology*. 2011;75(11):1353-8.
108. Bailey BJ, Johnson JT, Newlands SD. *Head & neck surgery--otolaryngology*: Lippincott Williams & Wilkins; 2006.
109. Gritzmam N, Rettenbacher T, Hollerweger A, Macheiner P, Hübner E. Sonography of the salivary glands. *European radiology*. 2003;13(5):964-75.
110. Shankar VN, Praveena V, Amingad BB. Ultrasonography of salivary gland: A pictorial review. *Journal of Oral and Maxillofacial Surgery, Medicine, and Pathology*. 2014;26(1):61-7.

111. Audi R, Audi P. The Cambridge dictionary of philosophy: Cambridge university press Cambridge; 1999.
112. Russell S, Norvig P. Artificial Intelligence: A Modern Approach, Global Edition, 4th Foundations, vol. 19. Pearson Education, Hoboken; 2021.
113. McCarthy J, Minsky ML, Rochester N, Shannon CE. A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. AI magazine. 2006;27(4):12-.
114. Bellman RE. Artificial intelligence: can computers think? (No Title). 1978.
115. Balakrishnan J, Dwivedi YK. Conversational commerce: entering the next stage of AI-powered digital assistants. Annals of Operations Research. 2024;333(2):653-87.
116. Dewitte S, Cornelis JP, Müller R, Munteanu A. Artificial intelligence revolutionises weather forecast, climate monitoring and decadal prediction. Remote Sensing. 2021;13(16):3209.
117. Khayyam H, Javadi B, Jalili M, Jazar RN. Artificial intelligence and internet of things for autonomous vehicles. Nonlinear approaches in engineering applications: Automotive Applications of engineering problems. 2020:39-68.
118. Yakan SA. Analysis of development of artificial intelligence in the game industry. International Journal of Cyber and IT Service Management. 2022;2(2):111-6.
119. Beer A, Gartner J, Musliu N, Schafhauser W, Slany W. An AI-based break-scheduling system for supervisory personnel. IEEE Intelligent Systems. 2010;25(2):60-73.
120. Vyas B. Java in Action: AI for Fraud Detection and Prevention. International Journal of Scientific Research in Computer Science, Engineering and Information Technology. 2023:58-69.
121. Song X, Yang S, Huang Z, Huang T, editors. The application of artificial intelligence in electronic commerce. Journal of Physics: Conference Series; 2019: IOP Publishing.
122. Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. Nature medicine. 2022;28(1):31-8.
123. Teng X, Gong Y, editors. Research on application of machine learning in data mining. IOP conference series: materials science and engineering; 2018: IOP Publishing.
124. Vidhya B, Nikhil Madhav M, Suresh Kumar M, Kalanandini S. AI based diagnosis of pneumonia. Wireless Personal Communications. 2022;126(4):3677-92.
125. Bellinger C, Mohamed Jabbar MS, Zaiane O, Osornio-Vargas A. A systematic review of data mining and machine learning for air pollution epidemiology. BMC public health. 2017;17:1-19.
126. Sarker IH. Machine learning: Algorithms, real-world applications and research directions. SN computer science. 2021;2(3):160.
127. Tiwari T, Tiwari T, Tiwari S. How Artificial Intelligence, Machine Learning and Deep.
128. Kim P. Matlab deep learning. With machine learning, neural networks and artificial intelligence. 2017;130(21).
129. Han J, Kamber M, Pei J. Data mining: concepts and techniques, Waltham, MA. Morgan Kaufman Publishers. 2012;10:978-1.
130. Sarker IH, Kayes A, Badsha S, Alqahtani H, Watters P, Ng A. Cybersecurity data science: an overview from machine learning perspective. Journal of Big data. 2020;7:1-29.
131. Benke K, Benke G. Artificial intelligence and big data in public health. International journal of environmental research and public health. 2018;15(12):2796.
132. Huang S, Yang J, Fong S, Zhao Q. Artificial intelligence in cancer diagnosis and prognosis: Opportunities and challenges. Cancer letters. 2020;471:61-71.
133. De La Vega FM, Chowdhury S, Moore B, Frise E, McCarthy J, Hernandez EJ, et al. Artificial intelligence enables comprehensive genome interpretation and nomination of candidate diagnoses for rare genetic diseases. Genome medicine. 2021;13:1-19.
134. Ran D, Yingli W, Haoxin Q. Artificial intelligence speech recognition model for correcting spoken English teaching. Journal of Intelligent & Fuzzy Systems. 2021;40(2):3513-24.

135. Ghodselahi A, Amirmadhi A. Application of artificial intelligence techniques for credit risk evaluation. *International Journal of Modeling and Optimization*. 2011;1(3):243.
136. Chandran V, Patil CK, Karthick A, Ganeshaperumal D, Rahim R, Ghosh A. State of charge estimation of lithium-ion battery for electric vehicles using machine learning algorithms. *World Electric Vehicle Journal*. 2021;12(1):38.
137. Sehgal N, Pandey KK. Artificial intelligence methods for oil price forecasting: a review and evaluation. *Energy Systems*. 2015;6:479-506.
138. Ahmed A, Aziz S, Qidwai U, Abd-Alrazaq A, Sheikh J. Performance of artificial intelligence models in estimating blood glucose level among diabetic patients using non-invasive wearable device data. *Computer Methods and Programs in Biomedicine Update*. 2023;3:100094.
139. Deo RC. Machine learning in medicine. *Circulation*. 2015;132(20):1920-30.
140. Richards BA, Lillicrap TP, Beaudoin P, Bengio Y, Bogacz R, Christensen A, et al. A deep learning framework for neuroscience. *Nature neuroscience*. 2019;22(11):1761-70.
141. Schaefer M, Michelin L, Kepner J. Naming schema for a human brain-scale neural network. *arXiv preprint arXiv:210910951*. 2021.
142. Aggarwal K, Mijwil MM, Al-Mistarehi A-H, Alomari S, Gök M, Alaabdin AMZ, et al. Has the future started? The current growth of artificial intelligence, machine learning, and deep learning. *Iraqi Journal for Computer Science and Mathematics*. 2022;3(1):115-23.
143. Mathew A, Amudha P, Sivakumari S. Deep learning techniques: an overview. *Advanced Machine Learning Technologies and Applications: Proceedings of AMLTA 2020*. 2021:599-608.
144. Ongsulee P, editor *Artificial intelligence, machine learning and deep learning*. 2017 15th international conference on ICT and knowledge engineering (ICT&KE); 2017: IEEE.
145. Sebastian N, Ankayarkanni B, editors. *Deep Learning applications to detect pneumonia on chest X-ray: A systematic study*. 2022 International Conference on Advanced Computing Technologies and Applications (ICACTA); 2022: IEEE.
146. Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*. 2012;25.
147. Kim J, Sangjun O, Kim Y, Lee M. Convolutional neural network with biologically inspired retinal structure. *Procedia Computer Science*. 2016;88:145-54.
148. Mehra R. Breast cancer histology images classification: Training from scratch or transfer learning? *Ict Express*. 2018;4(4):247-54.
149. Deng J, Dong W, Socher R, Li L-J, Li K, Fei-Fei L, editors. *Imagenet: A large-scale hierarchical image database*. 2009 IEEE conference on computer vision and pattern recognition; 2009: IEEE.
150. Morid MA, Borjali A, Del Fiol G. A scoping review of transfer learning research on medical image analysis using ImageNet. *Computers in biology and medicine*. 2021;128:104115.
151. Yaman S, Ünlü EI, Güler H, Sengur A, Acharya UR. Application of novel DIRF feature selection algorithm for automated brain disease detection. *Biomedical Signal Processing and Control*. 2023;85:105006.
152. Al Hadhrami E, Al Mufti M, Taha B, Werghi N, editors. *Transfer learning with convolutional neural networks for moving target classification with micro-Doppler radar spectrograms*. 2018 International Conference on Artificial Intelligence and Big Data (ICAIBD); 2018: IEEE.
153. Ahmad I. A hybrid rule-based and machine learning system for Arabic check courtesy amount recognition. *Sensors*. 2023;23(9):4260.
154. Nalluri S, Sasikala R. A deep neural architecture for SOTA pneumonia detection from chest X-rays. *International Journal of System Assurance Engineering and Management*. 2024;15(1):489-502.
155. Acharya UK, Ali MT, Ahmed MK, Siddiqui MT, Gupta H, Kumar S, et al. Hybrid deep neural network for automatic detection of COVID-19 using chest x-ray images. *International Journal of Imaging Systems and Technology*. 2023;33(4):1129-43.

156. Baltruschat IM, Steinmeister L, Ittrich H, Adam G, Nickisch H, Saalbach A, et al., editors. When does bone suppression and lung field segmentation improve chest x-ray disease classification? 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019); 2019: IEEE.
157. Deniz E, Şengür A, Kadiroğlu Z, Guo Y, Bajaj V, Budak Ü. Transfer learning based histopathologic image classification for breast cancer detection. *Health information science and systems*. 2018;6:1-7.
158. Lemley J, Bazrafkan S, Corcoran P, editors. *Transfer Learning of Temporal Information for Driver Action Classification*. MAICS; 2017.
159. Lee W, Jo O, Kim M. Application of end-to-end deep learning in wireless communications systems. *arXiv preprint arXiv:180802394*. 2018.
160. O'Mahony N, Campbell S, Carvalho A, Harapanahalli S, Hernandez GV, Krpalkova L, et al., editors. Deep learning vs. traditional computer vision. *Advances in Computer Vision: Proceedings of the 2019 Computer Vision Conference (CVC), Volume 1 1*; 2020: Springer.
161. Schweidtmann AM, Esche E, Fischer A, Kloft M, Repke JU, Sager S, et al. Machine learning in chemical engineering: A perspective. *Chemie Ingenieur Technik*. 2021;93(12):2029-39.
162. Kanawade B, Zaware S, Nandre J, Mahale Y, Dhake K. A Deep Learning Approach for Pneumonia Detection from X- ray Images. *International Journal of Intelligent Systems and Applications in Engineering*. 2023;11(2):262-6.
163. Singh N, Sabrol H. Convolutional neural networks-an extensive arena of deep learning. A comprehensive study. *Archives of Computational Methods in Engineering*. 2021;28(7):4755-80.
164. Çallı E, Sogancioglu E, van Ginneken B, van Leeuwen KG, Murphy K. Deep learning for chest X-ray analysis: A survey. *Medical Image Analysis*. 2021;72:102125.
165. Yun J, Cho YH, Lee SM, Hwang J, Lee JS, Oh Y-M, et al. Deep radiomics-based survival prediction in patients with chronic obstructive pulmonary disease. *Scientific reports*. 2021;11(1):15144.
166. İnik Ö, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*. 2017;6(3):85-104.
167. Jiang S, Qin S, Pulsipher JL, Zavala VM. Convolutional neural networks: Basic concepts and applications in manufacturing. *Artificial Intelligence in Manufacturing: Elsevier*; 2024. p. 63-102.
168. Kimura N, Yoshinaga I, Sekijima K, Azechi I, Baba D. Convolutional neural network coupled with a transfer-learning approach for time-series flood predictions. *Water*. 2019;12(1):96.
169. Ioffe S, Szegedy C, editors. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *International conference on machine learning*; 2015: pmlr.
170. Barhoom AM, Abu-Naser SS. Diagnosis of pneumonia using deep learning. 2022.
171. Albawi S, Mohammed TA, Al-Zawi S, editors. Understanding of a convolutional neural network. *2017 international conference on engineering and technology (ICET)*; 2017: IEEE.
172. Hochreiter S. The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*. 1998;6(02):107-16.
173. Pauly L, Hogg D, Fuentes R, Peel H, editors. Deeper networks for pavement crack detection. *Proceedings of the 34th ISARC*; 2017: IAARC.
174. Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*. 2021;8:1-74.
175. Byers B, Sheta A. Design of Convolutional Neural Networks for Fish Recognition and Tracking.

176. Scherer D, Müller A, Behnke S, editors. Evaluation of pooling operations in convolutional architectures for object recognition. International conference on artificial neural networks; 2010: Springer.
177. Guissous AE. Skin lesion classification using deep neural network. arXiv preprint arXiv:191107817. 2019.
178. Guo Y, Liu Y, Oerlemans A, Lao S, Wu S, Lew MS. Deep learning for visual understanding: A review. *Neurocomputing*. 2016;187:27-48.
179. Zhu J, Song J. An intelligent classification model for surface defects on cement concrete bridges. *Applied sciences*. 2020;10(3):972.
180. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*. 2014;15(1):1929-58.
181. Al-Janabi AA, Al-Janabi STF, Al-Khateeb B. Secure Data Computation Using Deep Learning and Homomorphic Encryption: A Survey. *International Journal of Online & Biomedical Engineering*. 2023;19(11).
182. Ding H, Wu J, Zhao W, Matinlinna JP, Burrow MF, Tsoi JK. Artificial intelligence in dentistry—A review. *Frontiers in Dental Medicine*. 2023;4:1085251.
183. Schleyer TK, Thyvalikakath TP, Spallek H, Torres-Urquidy MH, Hernandez P, Yuhaniak J. Clinical computing in general dentistry. *Journal of the American Medical Informatics Association*. 2006;13(3):344-52.
184. Chae YM, Yoo KB, Kim ES, Chae H. The adoption of electronic medical records and decision support systems in Korea. *Healthcare informatics research*. 2011;17(3):172-7.
185. Olsen GF, Brilliant SS, Primeaux D, Najarian K, editors. An image-processing enabled dental caries detection system. 2009 ICME International Conference on Complex Medical Engineering; 2009: IEEE.
186. Beltrán-Aguilar ED, Barker LK, Canto MT, Dye BA, Gooch BF, Griffin SO, et al. Surveillance for dental caries, dental sealants, tooth retention, edentulism, and enamel fluorosis—United States, 1988–1994 and 1999–2002. *MMWR Surveill Summ*. 2005;54(3):1-43.
187. Geetha V, Aprameya K, Hinduja DM. Dental caries diagnosis in digital radiographs using back-propagation neural network. *Health information science and systems*. 2020;8:1-14.
188. Abdalla-Aslan R, Yeshua T, Kabla D, Leichter I, Nadler C. An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral surgery, oral medicine, oral pathology and oral radiology*. 2020;130(5):593-602.
189. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, et al. Deep learning for the radiographic detection of apical lesions. *Journal of endodontics*. 2019;45(7):917-22. e5.
190. Saghiri MA, Asgar K, Boukani K, Lotfi M, Aghili H, Delvarani A, et al. A new approach for locating the minor apical foramen using an artificial neural network. *International endodontic journal*. 2012;45(3):257-65.
191. Aminoshariae A, Kulild J, Nagendrababu V. Artificial intelligence in endodontics: current applications and future directions. *Journal of endodontics*. 2021;47(9):1352-7.
192. de Oliveira Poswar F, Farias LC, de Carvalho Fraga CA, Bambirra Jr W, Brito-Júnior M, Sousa-Neto MD, et al. Bioinformatics, interaction network analysis, and neural networks to characterize gene expression of radicular cyst and periapical granuloma. *Journal of endodontics*. 2015;41(6):877-83.
193. Kök H, Izgi MS, Acilar AM. Determination of growth and development periods in orthodontics with artificial neural network. *Orthodontics & craniofacial research*. 2021;24:76-83.
194. Muraev AA, Tsai P, Kibardin I, Oborotistov N, Shirayeva T, Ivanov S, et al. Frontal cephalometric landmarking: humans vs artificial neural networks. *International Journal of Computerized Dentistry*. 2020;23(2).

195. 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):8012.
196. Auconi P, Scazzocchio M, Cozza P, McNamara Jr JA, Franchi L. Prediction of Class III treatment outcomes through orthodontic data mining. *European journal of orthodontics*. 2015;37(3):257-67.
197. Li P, Kong D, Tang T, Su D, Yang P, Wang H, et al. Orthodontic treatment planning based on artificial neural networks. *Scientific reports*. 2019;9(1):2037.
198. Patcas R, Timofte R, Volokitin A, Agustsson E, Eliades T, Eichenberger M, et al. Facial attractiveness of cleft patients: a direct comparison between artificial-intelligence-based scoring and conventional rater groups. *European journal of orthodontics*. 2019;41(4):428-33.
199. Patcas R, Bernini DA, Volokitin A, Agustsson E, Rothe R, Timofte R. Applying artificial intelligence to assess the impact of orthognathic treatment on facial attractiveness and estimated age. *International journal of oral and maxillofacial surgery*. 2019;48(1):77-83.
200. Kim BS, Yeom HG, Lee JH, Shin WS, Yun JP, Jeong SH, et al. Deep learning-based prediction of paresthesia after third molar extraction: A preliminary study. *Diagnostics*. 2021;11(9):1572.
201. Liu Z, Liu J, Zhou Z, Zhang Q, Wu H, Zhai G, et al. Differential diagnosis of ameloblastoma and odontogenic keratocyst by machine learning of panoramic radiographs. *International Journal of Computer Assisted Radiology and Surgery*. 2021;16:415-22.
202. Sukegawa S, Yoshii K, Hara T, Matsuyama T, Yamashita K, Nakano K, et al. Multi-task deep learning model for classification of dental implant brand and treatment stage using dental panoramic radiograph images. *Biomolecules*. 2021;11(6):815.
203. Chang H-J, Lee S-J, Yong T-H, Shin N-Y, Jang B-G, Kim J-E, et al. Deep learning hybrid method to automatically diagnose periodontal bone loss and stage periodontitis. *Scientific reports*. 2020;10(1):7531.
204. Lee CT, Kabir T, Nelson J, Sheng S, Meng HW, Van Dyke TE, et al. Use of the deep learning approach to measure alveolar bone level. *Journal of clinical periodontology*. 2022;49(3):260-9.
205. Cha J-Y, Yoon H-I, Yeo I-S, Huh K-H, Han J-S. Peri-implant bone loss measurement using a region-based convolutional neural network on dental periapical radiographs. *Journal of clinical medicine*. 2021;10(5):1009.
206. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep learning for the radiographic detection of periodontal bone loss. *Scientific reports*. 2019;9(1):8495.
207. Pareek M, Kaushik B. Artificial intelligence in prosthodontics: a scoping review on current applications and future possibilities. *Int J Adv Med*. 2022;9(3):367-70.
208. Roongruangsilp P, Khongkhunthian P. The learning curve of artificial intelligence for dental implant treatment planning: a descriptive study. *Applied Sciences*. 2021;11(21):10159.
209. Kong H-J, Kim Y-L. Application of artificial intelligence in dental crown prosthesis: a scoping review. *BMC Oral Health*. 2024;24(1):937.
210. Chen S-L, Chen T-Y, Huang Y-C, Chen C-A, Chou H-S, Huang Y-Y, et al. Missing teeth and restoration detection using dental panoramic radiography based on transfer learning with CNNs. *IEEE Access*. 2022;10:118654-64.
211. Vishwanathaiah S, Fageeh HN, Khanagar SB, Maganur PC. Artificial intelligence its uses and application in pediatric dentistry: a review. *Biomedicine*. 2023;11(3):788.
212. Wang Y, Hays R, Marcus M, Maida C, Shen J, Xiong D, et al. Developing children's oral health assessment toolkits using machine learning algorithm. *JDR Clinical & Translational Research*. 2020;5(3):233-43.
213. You W, Hao A, Li S, Wang Y, Xia B. Deep learning-based dental plaque detection on primary teeth: a comparison with clinical assessments. *BMC Oral Health*. 2020;20:1-7.

214. Kılıc MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, et al. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofacial Radiology*. 2021;50(6):20200172.
215. Karhade DS, Roach J, Shrestha P, Simancas-Pallares MA, Ginnis J, Burk ZJ, et al. An automated machine learning classifier for early childhood caries. *Pediatric dentistry*. 2021;43(3):191-7.
216. AYDIN KC. Ağız, Diş ve Çene Radyolojisinde Yapay Zekâ Uygulamaları Neler Yapabiliyor? *Türkiye Klinikleri Oral and Maxillofacial Radiology-Special Topics*. 2023;9(1):9-15.
217. Talpur S, Azim F, Rashid M, Syed SA, Talpur BA, Khan SJ. Uses of different machine learning algorithms for diagnosis of dental caries. *Journal of Healthcare Engineering*. 2022;2022(1):5032435.
218. Lai G, Dunlap C, Gluskin A, Nehme WB, Azim AA. Artificial intelligence in endodontics. *Journal of the California Dental Association*. 2023;51(1):2199933.
219. Khadivi G, Akhtari A, Sharifi F, Zargarian N, Esmaeili S, Ahsaie MG, et al. Diagnostic accuracy of artificial intelligence models in detecting osteoporosis using dental images: a systematic review and meta-analysis. *Osteoporosis International*. 2024:1-19.
220. Çiftçi BT, Aşantoğrol F. Utilization of machine learning models in predicting caries risk groups and oral health-related risk factors in adults. *BMC Oral Health*. 2024;24(1):430.
221. Kang CH, Kim SY. Real-time object detection and segmentation technology: an analysis of the YOLO algorithm. *JMST Advances*. 2023;5(2):69-76.
222. Haimar Z, Mateur K, Farhan Y, Madi AA, editors. Pothole Detection: A Performance Comparison Between YOLOv7 and YOLOv8. 2023 9th International Conference on Optimization and Applications (ICOA); 2023: IEEE.
223. Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z, editors. Rethinking the inception architecture for computer vision. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 2016.
224. Ali L, Alnajjar F, Jassmi HA, Gocho M, Khan W, Serhani MA. Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures. *Sensors*. 2021;21(5):1688.
225. Ayan E, Ünver HM, editors. Diagnosis of pneumonia from chest X-ray images using deep learning. 2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT); 2019: Ieee.
226. Gwyn T, Roy K, Atay M. Face recognition using popular deep net architectures: A brief comparative study. *Future Internet*. 2021;13(7):164.
227. Srinivasan K, Garg L, Datta D, Alaboudi AA, Jhanjhi N, Agarwal R, et al. Performance comparison of deep cnn models for detecting driver's distraction. *CMC-Computers, Materials & Continua*. 2021;68(3):4109-24.
228. Younis A, Qiang L, Nyatega CO, Adamu MJ, Kawuwa HB. Brain tumor analysis using deep learning and VGG-16 ensembling learning approaches. *Applied Sciences*. 2022;12(14):7282.
229. Likhari K, Ridhorkar S. Enhancing Skin Cancer Detection: A Comparative Analysis of Models with VGG-16, VGG-19, and Inception V3. *International Journal of Intelligent Systems and Applications in Engineering*. 2024;12(10s):502-14.
230. Kavitha B, Shaffi N, Mahmud M, Hajamohideen F, Narayanan P, editors. A New Model Evaluation Framework for Tamil Handwritten Character Recognition. *International Conference on Trends in Electronics and Health Informatics*; 2022: Springer.
231. Cao Z, Huang J, He X, Zong Z. BND-VGG-19: A deep learning algorithm for COVID-19 identification utilizing X-ray images. *Knowledge-Based Systems*. 2022;258:110040.
232. Alibabaei K, Gaspar PD, Lima TM, Campos RM, Girão I, Monteiro J, et al. A review of the challenges of using deep learning algorithms to support decision-making in agricultural activities. *Remote Sensing*. 2022;14(3):638.

233. Saritha S, Srinivas VS, Anuhya D, Pavithra G. Performance Analysis of Detection of Disease on Leaf Images with Inception V3 and Mobilenet Deep Learning Techniques. *Journal of Pharmaceutical Negative Results*. 2022;111-7.
234. Sandler M, Howard A, Zhu M, Zhmoginov A, Chen L-C, editors. *Mobilenetv2: Inverted residuals and linear bottlenecks*. Proceedings of the IEEE conference on computer vision and pattern recognition; 2018.
235. Nainan NA, Jeevika H, Jalan R, Karthik V, Shankar SP, editors. *Real Time Face Mask Detection Using MobileNetV2 and InceptionV3 Models*. 2021 IEEE Mysore Sub Section International Conference (MysuruCon); 2021: IEEE.
236. Akay M, Du Y, Serhsen CL, Wu M, Chen TY, Assassi S, et al. Deep learning classification of systemic sclerosis skin using the MobileNetV2 model. *IEEE Open Journal of Engineering in Medicine and Biology*. 2021;2:104-10.
237. Hicks SA, Strümke I, Thambawita V, Hammou M, Riegler MA, Halvorsen P, et al. On evaluation metrics for medical applications of artificial intelligence. *Scientific reports*. 2022;12(1):5979.
238. Handelman GS, Kok HK, Chandra RV, Razavi AH, Huang S, Brooks M, et al. Peering into the black box of artificial intelligence: evaluation metrics of machine learning methods. *American Journal of Roentgenology*. 2019;212(1):38-43.
239. Liu Y, Pang Z, Karlsson M, Gong S. Anomaly detection based on machine learning in IoT-based vertical plant wall for indoor climate control. *Building and Environment*. 2020;183:107212.
240. Lee J-H, Han S-S, Kim YH, Lee C, Kim I. Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral surgery, oral medicine, oral pathology and oral radiology*. 2020;129(6):635-42.
241. Lee S-H, Chen H-C. U-SSD: Improved SSD based on U-Net architecture for end-to-end table detection in document images. *Applied Sciences*. 2021;11(23):11446.
242. Monteiro MM, D'Epiro TTS, Bernardi L, Fossati ACM, Dos Santos MF, Lamers ML. Long- and short-term diabetes mellitus type 1 modify young and elder rat salivary glands morphology. *Archives of Oral Biology*. 2017;73:40-7.
243. Lee K-A, Lee S-H, Kim H-R. Ultrasonographic changes of major salivary glands in primary Sjögren's syndrome. *Journal of clinical medicine*. 2020;9(3):803.
244. Elghamry EG, Seleim HA, Yossef M, Mortada MA. Ultrasonography features of salivary gland in patients with rheumatoid arthritis and secondary Sjogren syndrome. *Zagazig University Medical Journal*. 2021;27(5):826-31.
245. Hammam N, Elzohri MH, Elsonbaty A, Eldaly ZH, Hammam O, Tarik D, et al. Diagnostic value of salivary gland ultrasonography for secondary Sjögren syndrome in patients with systemic lupus erythematosus. *Lupus*. 2022;31(9):1045-53.
246. Koch M, Sievert M, Iro H, Mantsopoulos K, Schapher M. Ultrasound in inflammatory and obstructive salivary gland diseases: own experiences and a review of the literature. *Journal of Clinical Medicine*. 2021;10(16):3547.
247. Parker G, Harnsberger H. Clinical-radiologic issues in perineural tumor spread of malignant diseases of the extracranial head and neck. *Radiographics*. 1991;11(3):383-99.
248. Barakos JA, Dillon WP, Chew WM. Orbit, skull base, and pharynx: contrast-enhanced fat suppression MR imaging. *Radiology*. 1991;179(1):191-8.
249. Schlakman BN, Yousem DM. MR of intraparotid masses. *American journal of neuroradiology*. 1993;14(5):1173-80.
250. Takahashi N, Okamoto K, Ohkubo M, Kawana M. High-resolution magnetic resonance of the extracranial facial nerve and parotid duct: demonstration of the branches of the intraparotid facial nerve and its relation to parotid tumours by MRI with a surface coil. *Clinical radiology*. 2005;60(3):349-54.

251. McGhee R, Chakeres D, Schmalbrock P, Brogan M, Negulesco J. The extracranial facial nerve: high resolution three-dimensional Fourier transform MR imaging. *American journal of neuroradiology*. 1993;14(2):465-72.
252. Tsang J, Yip W, Lau C, Li K, Lee Y, Wong J, et al. Visualization of normal intra-parotid facial nerve on MR: BTFE or GRASS? *Clinical radiology*. 2009;64(11):1115-8.
253. Murakami R, Baba Y, Nishimura R, Baba T, Matsumoto N, Yamashita Y, et al. MR sialography using half-Fourier acquisition single-shot turbo spin-echo (HASTE) sequences. *American journal of neuroradiology*. 1998;19(5):959-61.
254. Lomas DJ, Carroll NR, Johnson G, Antoun NM, Freer C. MR sialography. Work in progress. *Radiology*. 1996;200(1):129-33.
255. Uchida Y, Minoshima S, Kawata T, Motoori K, Nakano K, Kazama T, et al. Diagnostic value of FDG PET and salivary gland scintigraphy for parotid tumors. *Clinical nuclear medicine*. 2005;30(3):170-6.
256. Howlett D, Menezes L, Bell D, Ahmed I, Witcher T, Bhatti N, et al. Ultrasound-guided core biopsy for the diagnosis of lumps in the neck: results in 82 patients. *British Journal of Oral and Maxillofacial Surgery*. 2006;44(1):34-7.
257. Howlett D. Diagnosing a parotid lump: fine needle aspiration cytology or core biopsy? *The british journal of Radiology*. 2006;79(940):295-7.
258. Kress E, Schulz H, Neumann T. Diagnosis of diseases of the large salivary glands of the head by ultrasound, sialography and CT-sialography. A comparison of methods. *HNO*. 1993;41(7):345-51.
259. Delli K, Dijkstra PU, Stel AJ, Bootsma H, Vissink A, Spijkervet FK. Diagnostic properties of ultrasound of major salivary glands in Sjögren's syndrome: a meta-analysis. *Oral diseases*. 2015;21(6):792-800.
260. Delli K, Arends S, van Nimwegen JF, Dijkstra PU, Stel AJ, Spijkervet FK, et al. Ultrasound of the major salivary glands is a reliable imaging technique in patients with clinically suspected primary Sjögren's syndrome. *Ultraschall in der Medizin-European Journal of Ultrasound*. 2018;39(03):328-33.
261. Fana V, Dohn UM, Krabbe S, Terslev L. Application of the OMERACT Grey-scale Ultrasound Scoring System for salivary glands in a single-centre cohort of patients with suspected Sjögren's syndrome. *RMD open*. 2021;7(2):e001516.
262. Jousse-Joulin S, d'Agostino MA, Nicolas C, Naredo E, Ohrndorf S, Backhaus M, et al. Video clip assessment of a salivary gland ultrasound scoring system in Sjögren's syndrome using consensual definitions: an OMERACT ultrasound working group reliability exercise. *Annals of the rheumatic diseases*. 2019;78(7):967-73.
263. Zhang X, Feng R, Zhao J, Wang Y, He J, Liu L, et al. Salivary gland ultrasonography in primary Sjögren's syndrome from diagnosis to clinical stratification: a multicentre study. *Arthritis Research & Therapy*. 2021;23:1-9.
264. Wernicke D, Hess H, Gromnica-Ihle E, Krause A, Schmidt WA. Ultrasonography of salivary glands--a highly specific imaging procedure for diagnosis of Sjögren's syndrome. *The Journal of Rheumatology*. 2008;35(2):285-93.
265. Theander E, Mandl T. Primary Sjögren's syndrome: diagnostic and prognostic value of salivary gland ultrasonography using a simplified scoring system. *Arthritis Care & Research*. 2014;66(7):1102-7.
266. Hafez AE, Taha AM, Moshirif A, Aly HM, Abdel Noor R, Mortada M, et al. Ultrasound abnormalities of the major salivary glands in Egyptian patients with systemic sclerosis. *Clinical Rheumatology*. 2023;42(12):3351-60.
267. Ozturk EMA, Yalcin ED. Evaluation of submandibular and parotid salivary glands by ultrasonography in patients with diabetes. *Journal of Oral Rehabilitation*. 2024.
268. Kiranatlı M, Yurttaş M, Güngör M, Canbaz Kabay S. Evaluation of major salivary glands with ultrasonography in multiple sclerosis patients. *BMC Oral Health*. 2024;24(1):245.

269. Görgün EA, Çağlayan F. EVALUATION OF ULTRASONOGRAPHIC FINDINGS OF SALIVARY GLANDS IN HEALTHY POPULATION. *Nobel Medicus Journal*. 2023;19(1).
270. Adamopoulou E, Moussiades L, editors. An overview of chatbot technology. IFIP international conference on artificial intelligence applications and innovations; 2020: Springer.
271. Wagner TL, Blewer A. "The word real is no longer real": Deepfakes, gender, and the challenges of ai-altered video. *Open Information Science*. 2019;3(1):32-46.
272. Hung KF, Ai QYH, Leung YY, Yeung AWK. Potential and impact of artificial intelligence algorithms in dento-maxillofacial radiology. *Clinical Oral Investigations*. 2022;26(9):5535-55.
273. Ahmed WM, Azhari AA, Fawaz KA, Ahmed HM, Alsadah ZM, Majumdar A, et al. Artificial intelligence in the detection and classification of dental caries. *The Journal of Prosthetic Dentistry*. 2023.
274. Do S, Song KD, Chung JW. Basics of deep learning: a radiologist's guide to understanding published radiology articles on deep learning. *Korean journal of radiology*. 2020;21(1):33-41.
275. Zheng Z, Yan H, Setzer FC, Shi KJ, Mupparapu M, Li J. Anatomically constrained deep learning for automating dental CBCT segmentation and lesion detection. *IEEE Transactions on Automation Science and Engineering*. 2020;18(2):603-14.
276. Fontenele RC, Gerhardt MdN, Picoli FF, Van Gerven A, Nomidis S, Willems H, et al. Convolutional neural network-based automated maxillary alveolar bone segmentation on cone-beam computed tomography images. *Clinical Oral Implants Research*. 2023;34(6):565-74.
277. Sukegawa S, Yoshii K, Hara T, Yamashita K, Nakano K, Yamamoto N, et al. Deep neural networks for dental implant system classification. *Biomolecules*. 2020;10(7):984.
278. Yaji A, Prasad S, Pai A. Artificial intelligence in dento-maxillofacial radiology. *Acta Sci Dent Sci*. 2019;3(1):116-21.
279. Keser G, Bayrakdar IS, Pekiner FN, Çelik Ö, Orhan K. A deep learning approach for masseter muscle segmentation on ultrasonography. *Journal of Ultrasonography*. 2022;22(91):e204-e8.
280. Chifor R, Hotoleanu M, Marita T, Arsenescu T, Socaciu MA, Badea IC, et al. Automatic segmentation of periodontal tissue ultrasound images with artificial intelligence: a novel method for improving dataset quality. *Sensors*. 2022;22(19):7101.
281. Nguyen K-CT, Le BM, Li M, Almeida FT, Major PW, Kaipatur NR, et al. Localization of cementoenamel junction in intraoral ultrasonographs with machine learning. *Journal of Dentistry*. 2021;112:103752.
282. Matsuo H, Nishio M, Kanda T, Kojita Y, Kono AK, Hori M, et al. Diagnostic accuracy of deep-learning with anomaly detection for a small amount of imbalanced data: discriminating malignant parotid tumors in MRI. *Scientific Reports*. 2020;10(1):19388.
283. Xia X, Feng B, Wang J, Hua Q, Yang Y, Sheng L, et al. Deep learning for differentiating benign from malignant parotid lesions on MR images. *Frontiers in Oncology*. 2021;11:632104.
284. Hu Z, Wang B, Pan X, Cao D, Gao A, Yang X, et al. Using deep learning to distinguish malignant from benign parotid tumors on plain computed tomography images. *Frontiers in Oncology*. 2022;12:919088.
285. Wei W, Xu J, Xia F, Liu J, Zhang Z, Wu J, et al. Deep learning-assisted diagnosis of benign and malignant parotid gland tumors based on automatic segmentation of ultrasound images: a multicenter retrospective study. *Frontiers in Oncology*. 2024;14:1417330-.
286. He Y, Zheng B, Peng W, Chen Y, Yu L, Huang W, et al. An ultrasound-based ensemble machine learning model for the preoperative classification of pleomorphic adenoma and Warthin tumor in the parotid gland. *European radiology*. 2024:1-15.
287. Vukicevic AM, Radovic M, Zabotti A, Milic V, Hocevar A, Callegher SZ, et al. Deep learning segmentation of primary Sjögren's syndrome affected salivary glands from ultrasonography images. *Computers in Biology and Medicine*. 2021;129:104154.

288. Tu CH, Wang RT, Wang BS, Kuo CE, Wang EY, Tu CT, et al. Neural network combining with clinical ultrasonography: a new approach for classification of salivary gland tumors. *Head & Neck*. 2023;45(8):1885-93.
289. Arso VM, Alen Z, Vera M, Alojzija H, Georgios F, Tzioufas A, et al., editors. Scoring Primary Sjögren's syndrome affected salivary glands ultrasonography images by using deep learning algorithms. 2021 IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE); 2021: IEEE.
290. Geng Y, Zhang X, Zhang Z. POS0928 DEEP LEARNING BASED ASSESSMENT OF SALIVARY GLAND ULTRASONOGRAPHY IMAGES FOR SUPPORTING THE DIAGNOSIS OF PRIMARY SJÖGREN'S SYNDROME. BMJ Publishing Group Ltd; 2023.
291. Wei W, Xu J, Xia F, Liu J, Zhang Z, Wu J, et al. Deep learning-assisted diagnosis of benign and malignant parotid gland tumors based on automatic segmentation of ultrasound images: a multicenter retrospective study. *Frontiers in Oncology*. 2024;14.
292. Olivier A, Hoffmann C, Jousse-Joulin S, Mansour A, Bressollette L, Clement B. Machine and Deep Learning Approaches Applied to Classify Gougerot–Sjögren Syndrome and Jointly Segment Salivary Glands. *Bioengineering*. 2023;10(11):1283.
293. Liao L-J, Cheng P-C, Chan F-T. Machine Learning on Ultrasound Texture Analysis Data for Characterizing of Salivary Glandular Tumors: A Feasibility Study. *Diagnostics*. 2024;14(16):1761.
294. Kise Y, Shimizu M, Ikeda H, Fujii T, Kuwada C, Nishiyama M, et al. Usefulness of a deep learning system for diagnosing Sjögren's syndrome using ultrasonography images. *Dentomaxillofacial Radiology*. 2020;49(3):20190348.
295. Wang Y, Gao J, Yin Z, Wen Y, Sun M, Han R. Differentiation of benign and malignant parotid gland tumors based on the fusion of radiomics and deep learning features on ultrasound images. *Frontiers in Oncology*. 2024;14.
296. Wang Y, Xie W, Huang S, Feng M, Ke X, Zhong Z, et al. The diagnostic value of ultrasound-based deep learning in differentiating parotid gland tumors. *Journal of Oncology*. 2022;2022(1):8192999.
297. Zhang G, Zhu L, Huang R, Xu Y, Lu X, Chen Y, et al. A deep learning model for the differential diagnosis of benign and malignant salivary gland tumors based on ultrasound imaging and clinical data. *Quantitative Imaging in Medicine and Surgery*. 2023;13(5):2989.
298. Vukicevic AM, Milic V, Zabotti A, Hocevar A, De Lucia O, Filippou G, et al. Radiomics-based assessment of primary Sjögren's syndrome from salivary gland ultrasonography images. *IEEE Journal of Biomedical and Health Informatics*. 2019;24(3):835-43.
299. De Vita S, Lorenzon G, Rossi G, Sabella M, Fossaluzza V. Salivary gland echography in primary and secondary Sjögren's syndrome. *Clinical and experimental rheumatology*. 1992;10(4):351-6.