

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**DIŞ RÖNTGEN GÖRÜNTÜLERİNDE HASTALIK VE
MATERYAL TESPİTİ İÇİN MAKİNE ÖĞRENMESİNE DAYALI
YAKLAŞIMLAR**

Andaç İMAK

Doktora Tezi

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Elektrik Elektronik Mühendisliği Teknolojileri Programı

Telekomünikasyon Bilim Dalı

HAZİRAN 2023

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik Elektronik Mühendisliği Anabilim Dalı
Elektrik Elektronik Mühendisliği Teknolojileri Programı

Doktora Tezi

DIŞ RÖNTGEN GÖRÜNTÜLERİNDE HASTALIK VE MATERYAL TESPİTİ İÇİN MAKİNE ÖĞRENMESİNE DAYALI YAKLAŞIMLAR

Tez Yazarı
Andaç İMAK

Danışman
Prof. Dr. Abdulkadir ŞENGÜR

HAZİRAN 2023
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik Elektronik Mühendisliği Anabilim Dalı
Elektrik Elektronik Mühendisliği Teknolojileri Programı

Doktora Tezi

Başlığı:	Diş Röntgen Görüntülerinde Hastalık Ve Materyal Tespiti İçin Makine Öğrenmesine Dayalı Yaklaşımlar
Yazarı:	Andaç İMAK
İlk Teslim Tarihi:	30.05.2023
Savunma Tarihi:	21.06.2023

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. Abdulkadir ŞENGÜR Fırat Üniversitesi, Teknoloji Fakültesi	İmza Onayladım
Başkan:	Doç. Dr. Fatih DEMİR Fırat Üniversitesi, Teknik Bilimler MYO	Onayladım
Üye:	Dr. Öğr. Üyesi Yaman AKBULUT Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Doç. Dr. Muammer TÜRKOĞLU Samsun Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Doç. Dr. Muzaffer ASLAN Bingöl Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Diş Röntgen Görüntülerinde Hastalık Ve Materyal Tespiti İçin Makine Öğrenmesine Dayalı Yaklaşımlar ” Başlıklı Doktora Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

21.06.2023

Andaç İMAK



ÖNSÖZ

Bu tez, diş röntgen görüntülerinde derin öğrenme yöntemlerinin kullanılmasıyla hastalık ve materyal tespiti konusuna odaklanmaktadır. Günümüzde diş sağlığı, insan sağlığının önemli bir bileşeni olarak kabul edilmekte ve röntgen görüntüleme, diş hekimliği pratiğinde yaygın bir şekilde kullanılmaktadır. Diş röntgenleri, diş hekimlerine hastalıkların teşhisi, tedavisi ve takibi konularında önemli bilgiler sağlamaktadır. Derin öğrenme tekniklerinin diş röntgen görüntülerinde hastalık ve materyal tespiti alanında nasıl kullanılabileceğinin araştırılması, aynı zamanda uygulamaları gerçekleştirilmiştir. Bu tez çalışması, diş hekimliği pratiğinde hastalık tespiti ve materyal tespiti gibi önemli görevlerin otomatikleştirilmesinde derin öğrenme tekniklerinin potansiyelini vurgulamaktadır. Dört farklı problem için oluşturulan özgün veri setleri ile derin öğrenme tabanlı sınıflandırma ve nesne bulma yaklaşımları önerilmiştir.

Bu tez çalışması, Türkiye Küçük ve Orta Ölçekli İşletmeleri Geliştirme Kurumu (KOSGEB) tarafından Ar-Ge ve Yenilikçiliği Destekleme Programı 62146 protokol numaralı proje ile desteklenmiştir. Çalışmalar Fırat Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulunun 31/12/2020 tarih ve 2020/17-15 sayılı izni ile gerçekleştirilmiştir.

“Oral radyolojik görüntüleme tekniklerinde yapay zeka tabanlı uzman sistem tasarımı” projesi kapsamındaki bu çalışmayı destekleyen KOSGEB kurumuna sağladıkları destek ve katkılardan dolayı teşekkür ederiz.

Tez çalışmalarımın her sürecinde bana doğru yolu gösteren, her türlü zorlukta varlığını hissettiren, her zaman çalışmaktan ve öğrencisi olmaktan büyük bir gurur ve onur duyduğum danışman hocam Prof. Dr. Abdulkadir ŞENGÜR’e

Akademik hayata ilk adımı attığım dönemde bana rehberlik eden, bilgi ve deneyimlerini benimle paylaşan saygıdeğer hocam Doç. Dr. Ömer Faruk ALÇİN’e

Bilgi birikimi ve tecrübesini esirgmeden bu süreçte bir yol gösterici olan ve sürekli beni motive eden hocalarım Doç. Dr. Muammer TÜRKOĞLU’na ve Dr. Öğr. Üyesi Adalet ÇELEBİ’ye

Beni her durumda destekleyen ve motive eden, hayatımın her anında her kararımdayanım olan Fethiye Merve KAVAK’a

Doktora eğitim sürecim boyunca, yoğunluğumu, sıkıntılarımı ve stresimi anlayan, her adımda yanımda, bugünlere gelmemde büyük emeği, hayatımın her anında bana destek ve haklarını hiçbir zaman ödeyemeyeceğim kıymetlilerim annem Leyla İMAK, babam Mehmet İMAK ve abim Dr. Öğr. Üyesi Anıl İMAK’a en içten şükranlarımı sunuyorum teşekkür ediyorum.

Andaç İMAK
ELAZIĞ, 2023

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLOLAR LİSTESİ	xii
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
1.1. Literatür İncelemesi.....	3
1.1.1. Görüntü Kontrastının Geliştirilmesine Yönelik Çalışmalar	3
1.1.2. Çürük Tespitine Yönelik Çalışmalar	4
1.1.3. Maksiller Sinüs Tespitine Yönelik Çalışmalar	6
1.1.4. Gömülü Diş Tespitine Yönelik Çalışmalar	7
1.2. Önerilen Sistemin Genel Çerçevesi	9
1.2.1. Tezin Amacı	9
1.2.2. Tezin Çıktıları	10
1.2.3. Tezin Yenilikçi Yönü ve Ar-Ge Niteliği	10
1.2.4. Tezin Organizasyonu.....	11
2. TEORİK ALT YAPI.....	12
2.1. Diş Anatomisi	12
2.1.1. Diş Röntgen Türleri.....	13
2.1.2. Diş Çürüğü	14
2.1.3. Apse ve Kist	15
2.1.4. Gömülü Diş	16
2.1.5. Maksiller Sinüs.....	17
2.1.6. Diş Materyalleri.....	18
3. MATERYAL VE METOT.....	19
3.1. Derin Öğrenme	19
3.1.1. Evrimsel Sinir Ağlarının Bileşenleri.....	21
3.1.2. AlexNet	27
3.1.3. MobileNetV2.....	28
3.1.4. Transfer Öğrenme	29
3.1.5. Özel Blok Yapıları	31
3.1.6. ResNet Mimarisi	31
3.1.7. DenseNet Mimarisi	33
3.1.8. Çift Yönlü Evrimsel Uzun Kısa Süreli Bellek	33
3.1.9. Dönüştürücüler ve Swin Transformatör	35
3.1.10. Kodlayıcı ve Kod Çözücü Ağlar	37
3.1.11. Bölgesel Evrimli Sinir Ağları	38
3.2. Graf Kesim	39
3.3. Sınıflandırma Modelleri	41
3.4. Sınıflandırma Performans Metrikleri.....	43

4. PANORAMİK DİŞ RÖNTGEN GÖRÜNTÜLERİNDE DHB-ESA, GRAF KESİM VE ŞEKİL ÖZELLİKLERİNE DAYALI DİŞ MATERYAL TESPİTİ UYGULAMASI.....	45
4.1. Veri Seti.....	45
4.2. Önerilen Yöntem	46
4.3. Deneysel Çalışmalar ve Sonuçları	49
5. PERİAPİKAL DİŞ RÖNTGEN GÖRÜNTÜLERİNDE SKOR TABANLI ÇOK GİRİŞLİ DERİN EVRİŞİMSSEL SİNİR AĞINA DAYALI DİŞ ÇÜRÜĞÜ TESPİTİ UYGULAMASI	57
5.1. Veri Seti.....	57
5.2. Önerilen Yöntem	58
5.3. Deneysel Çalışmalar ve Sonuçları	61
6. KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE RESNET VE SWIN TRANSFORMATÖR TABANLI UNET MİMARİSİNE DAYALI MAKSİLLER SİNÜS TESPİTİ UYGULAMASI	67
6.1. Veri Seti.....	67
6.2. Önerilen Yöntem	68
6.3. Deneysel Çalışmalar ve Sonuçları	71
7. PANORAMİK DİŞ RÖNTGEN GÖRÜNTÜLERİNDE ARTIK BLOKLAR, DEĞİŞTİRİLMİŞ TERS ARTIK BLOK, BCONVLSTM'YE DAYALI GÖMÜLÜ DİŞ TESPİTİ UYGULAMASI	77
7.1. Veri Seti.....	77
7.2. Önerilen Yöntem	77
7.3. Deneysel Çalışmalar ve Sonuçları	81
8. SONUÇLAR.....	89
ÖNERİLER	92
KAYNAKLAR.....	93
ÖZGEÇMİŞ	

ÖZET

Diş Röntgen Görüntülerinde Hastalık Ve Materyal Tespiti İçin Makine Öğrenmesine Dayalı Yaklaşımlar

Andaç İMAK

Doktora Tezi

FIRAT ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı
Elektrik Elektronik Mühendisliği Teknolojileri Programı
Haziran 2023, Sayfa: xvi + 103

Son zamanlarda bilgisayar yazılım ve donanım teknolojisindeki hızlı gelişmeler, dijital dünyanın ve iletişimin gelişimiyle birlikte, nesnelerin interneti kavramının popülerlik kazanmasına yol açmıştır. Teknolojik ilerlemeler, özellikle nesne sınıflandırma, nesne tespiti ve örüntü tanıma gibi alanlarda da büyük bir etkiye sahiptir. Bu tez çalışması, diş röntgen görüntülerinde derin öğrenme yöntemlerinin kullanılmasıyla hastalık ve materyal tespiti konusunu ele almaktadır. Günümüzde diş sağlığı, tıp alanında önemli bir konudur ve diş röntgen görüntülerinin doğru bir şekilde analiz edilmesi, doğru tanı ve tedavi için büyük bir öneme sahiptir. Tez çalışması, diş hekimlerinin tanı ve tedavi süreçlerinde daha doğru ve hızlı kararlar almalarına yardımcı olacak potansiyele sahip olan derin öğrenme yöntemlerini diş röntgen görüntülerinde kullanma konusunda bir adım atmaktadır. Literatürdeki mevcut çalışmalarda, bu alanda kullanılabilecek yeterli ve özgün veri setlerinin eksikliği gözlemlenmiştir. Bu nedenle, tez çalışmasının bir parçası olarak, uzman bir diş hekimi yardımı ile incelenerek özgün bir veri seti oluşturulmuştur. Bu özgün veri seti, tez çalışmasının temelini oluşturmakta ve önerilen derin öğrenme tabanlı algoritmalarının doğruluğu ve performansı üzerinde değerlendirilmektedir. Ayrıca önerilen bu özgün yöntemlerin başarısını analiz etmek için güncel modellerle karşılaştırılmıştır. Elde edilen sonuçlar, önerilen yöntemlerin etkili olduğunu, literatürdeki eksikliği gidererek diş röntgen görüntülerinde hastalık ve materyal tespiti konusunda daha güvenilir ve etkili yöntemlerin geliştirilmesine katkı sağlamaktadır.

Anahtar Kelimeler: Derin öğrenme, Diş röntgen görüntüleri, Kodlayıcı-kod çözücü, Hastalık ve materyal tespiti, Yapay zeka

ABSTRACT

Machine Learning-Based Approaches for Disease and Material Detection in Dental X-Ray Images

Andaç İMAK

Ph.D. Thesis

FIRAT UNIVERSITY

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Electrical and Electronics Engineering Technologies

June 2023, Pages: xvi + 103

Recently, rapid developments in computer software and hardware technology, along with the development of the digital world and communication, have led to the popularity of the concept of the internet of things. Technological advances also have a major impact, especially in areas such as object classification, object detection, and pattern recognition. This Ph.D. thesis study deals with the detection of disease and material by using deep learning methods in dental x-ray images. Today, dental health is an important issue in the field of medicine and accurate analysis of dental x-ray images is of great importance for correct diagnosis and treatment. The thesis study takes a step forward in using deep learning methods in dental x-ray images, which have the potential to help dentists make more accurate and faster decisions in the diagnosis and treatment processes. In the current studies in the literature, it has been observed that there is a lack of sufficient and original data sets that can be used in this field. Therefore, as a part of the thesis study, an original data set was created by examining it with the help of a specialist dentist. This original data set forms the basis of the thesis and is evaluated on the accuracy and performance of the proposed deep learning-based algorithms. In addition, these original methods were compared with current models to analyze the success of these proposed methods. The results obtained contribute to the development of more reliable and effective methods for the detection of disease and material in dental x-ray images by eliminating the deficiency in the literature, that the proposed methods are effective.

Keywords: Deep learning, Dental X-ray images, Encoder-Decoder, Disease and material detection, Artificial intelligence

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Dişin yapısı.....	12
Şekil 2.2. Bitewing röntgen	13
Şekil 2.3. Periapikal röntgen	14
Şekil 2.4. Occlusal röntgen [3]	14
Şekil 2.5. Panoramik röntgen	14
Şekil 2.6. Diş röntgen görüntüsünde diş çürüğü.....	15
Şekil 2.7. Diş bölgesinde apse oluşumu	15
Şekil 2.8. Apseler gerçekleşmiş diş röntgeni görüntüsü	16
Şekil 2.9. Diş röntgeninde tespit edilmiş (a) kist röntgeni, (b) müzdarip hasta.....	16
Şekil 2.10. Gömülü diş röntgeni görüntüsü.....	17
Şekil 2.11. Maksiller sinüs	17
Şekil 2.12. Diş materyalleri.....	18
Şekil 3.1. ScienceDirect veritabanında “Deep Learning” anahtar kelimesini içeren yayın sayısı	20
Şekil 3.2. ESA mimarilerinin genel yapısı [67].....	21
Şekil 3.3. Evrişim işlemi ile ilgili örnek bir uygulama.....	22
Şekil 3.4. Havuzlama işlemi için örnek bir gösterim.....	24
Şekil 3.5. Yukarı örnekleme işlemi için örnek bir gösterim	24
Şekil 3.6. Dropout uygulanmış ağ örneği	26
Şekil 3.7. AlexNet mimarisi	28
Şekil 3.8. MobileNetV2 genel yapısı.....	29
Şekil 3.9. Artık blok	32
Şekil 3.10. (a) ESA mimarisi, (b) ResNet mimarisi, (c) DenseNet mimarisi [58].....	33
Şekil 3.11. LSTM mimarisinin yapısı	34
Şekil 3.12. (a) Transformer blok yapısı, (b) Swin transformer blok yapısı ve (c) Swin transformer kayan pencere modeli.....	36
Şekil 3.13. Parça genişletme katmanı.....	37
Şekil 3.14. Kodlayıcı ve kod çözücü ağlarının genel yapısı	37
Şekil 3.15. Temel UNet mimarisi [110]	38
Şekil 3.16. DHB-ESA mimarisinin yapısı [119]	39
Şekil 3.17. Bir 3×3 s/t graf kesim bölütleme modeli [125]	41
Şekil 3.18. DVM hiperdüzlem ayırımı	42

Şekil 4.1. Veri setindeki bazı panoramik diş görüntü örnekleri	45
Şekil 4.2. Şekil 4.1’de verilen görüntülerin maskesi	46
Şekil 4.3. Önerilen yöntemin ilk kısmı.....	46
Şekil 4.4. Önerilen yöntemin ikinci kısmı.....	48
Şekil 4.5. DHB-ESA modelinin bazı örnek çıktıları	50
Şekil 4.6. DHB-ESA modelinin ROI düzeltilmiş çıktıları.....	50
Şekil 4.7. GK yönteminin karalamaları	51
Şekil 4.8. Özellik çıkarma için blob tespiti	51
Şekil 4.9. 2B çizimde ana eksen uzunluğu özelliğinin küçük eksen uzunluğu özelliklerine göre dağılımı..	52
Şekil 4.10. DVM sınıflandırıcısı için elde edilen karışıklık matrisi	54
Şekil 4.11. DVM sınıflandırıcısı için ROC eğrisi.....	55
Şekil 4.12. Görsel bölütleme sonuçlarının karşılaştırılması	56
Şekil 5.1. Bu uygulamada kullanılan periapikal diş görüntüleri.....	58
Şekil 5.2. Önerilen mimarinin yapısı.....	59
Şekil 5.3. Önerilen ön işleme aşaması	59
Şekil 5.4. Önerilen modelin karışıklık matrisi ve ROC diyagramı.....	62
Şekil 5.5. Önerilen modelin artan iterasyon sayılarına karşı eğitim doğruluğu ve kaybı grafikleri	63
Şekil 5.6. Çürük görüntüsünün aktivasyon haritalarına dayalı örnekler.....	63
Şekil 6.1. Bu çalışmada kullanılan bazı KIBT görüntü örnekleri.....	68
Şekil 6.2. Res-Swin-UNet Mimarisinin yapısı	69
Şekil 6.3. (a) Resnet50 ve Resnet101 mimarileri ve (b) katman blok yapıları	69
Şekil 6.4. Önerilen her bir yöntem için yanlış pozitif oranı ile gerçek pozitif oranı ve duyarlılık ile kesinlik eğrileri.....	72
Şekil 6.5. Önerilen modellerin görsel sonuçları	73
Şekil 6.6. Önerilen modellerin görsel bölütlemesinin son teknoloji yöntemlerle karşılaştırılması.....	75
Şekil 7.1 Veri setindeki bazı panoramik diş görüntüsü ve maskesi.....	78
Şekil 7.2. Gömülü diş röntgen görüntüsü ve veri arttırma.....	78
Şekil 7.3. (a) MobileNetV2’nin genel yapısı (b) Değiştirilmiş ters çevrilmiş artık blok.....	79
Şekil 7.4. ResMIBCU-Net mimarisinin yapısı.....	81
Şekil 7.5. Modellerin eğitim görselleştirmesi; (a) doğruluk eğrisi, (b) kayıp eğrisi	82
Şekil 7.6. Önerilen yöntemin ROC eğrisi.....	83
Şekil 7.7. Önerilen yöntemin bölütleme performansının görselleştirilmesi	83
Şekil 7.8. Yanlış bölütlemeler için bazı örnekler	84

Şekil 7.9. Çalışmada kullanılan elemanların çeşitli U-Net modelleri: (a) ResU-Net, (b) Değiştirilmiş-Res/BConvLSTMU-Net, (c) BConvLSTMU-Net	85
Şekil 7.10. ResU-Net, Değiştirilmiş-Res/BConvLSTMU-Net, BConvLSTMU-Net ve önerilen yöntem bölütleme sonuçları.....	86
Şekil 7.11. Farklı mimariler ile önerilen modelin görsel bölütleme sonuçlarının karşılaştırılması	88



TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. Popüler olarak kullanılan aktivasyon fonksiyonları.....	25
Tablo 3.2. Transfer öğrenme için sıklıkla kullanılan ağ modelleri	30
Tablo 4.1. AlexNet mimarisinin kaydedilmiş katmanları	47
Tablo 4.2. Sınıflar için özelliklerin dağılımı	52
Tablo 4.3. Yapılan sınıflandırmalar için ortalama doğruluk yüzdeleri	54
Tablo 4.4. Diğer yöntemler için ortalama doğruluk yüzdeleri	56
Tablo 5.1. Önerilen çok girişli AlexNet mimarisi.....	60
Tablo 5.2. Önerilen skora dayalı yaklaşımın sözde kodu.....	60
Tablo 5.3. Mevcut çalışmada kullanılan derin ağ parametreleri	61
Tablo 5.4. Deneysel çalışmaları-I sonuçları (%) (transfer öğrenme)	61
Tablo 5.5. Deneysel çalışmalar-II sonuçları (%) (sıfırdan eğitim).....	64
Tablo 5.6. Önceden eğitilmiş derin modellerin sonuçları (%)	65
Tablo 5.7. Önceki çalışmaların önerilen modelle karşılaştırılması	66
Tablo 6.1. Res-Swin-UNet ağının katman ve parametre ayarları	70
Tablo 6.2. Önerilen modellerin performansı (%).....	72
Tablo 6.3. Önerilen modelin önceki çalışmalar ile karşılaştırılması	74
Tablo 6.4. Önerilen modelin performanslarının (%) güncel yöntemlerle karşılaştırılması	75
Tablo 7.1. Test seti için performans değerlendirme ölçütleri.....	82
Tablo 7.2. Bu çalışmada U-Net modelleri kullanılarak elde edilen doğrulukların özeti (Şekil 7.9)	86
Tablo 7.3. Önerilen yöntemin diğer U-Net tabanlı mimariler ile performans karşılaştırması.....	87

SİMGELER VE KISALTMALAR

Simgeler

$(*)$	: Evrişim operatörü
$(\odot)$	: Hadamard çarpımı
$\vec{w}_t, \vec{w}_t$	: Sırasıyla ileri ve geri LSTM ağırlıkları
$\hat{z}_1$	: Çok başlı öz dikkat çıkış özellik haritası
b_y	: Çıktı katmanının biası
C_t	: Çıktılar
f_t	: Unutma kapısı
g^{LSTM}	: LSTM ağının çıktısı
H_ζ	: Çıktının yükseklik değeri
h_t	: Gizli durumlar
i_t	: Giriş kapısı
o_t	: Çıkış kapısı
W_ζ	: Çıktının genişlik değeri
X_t	: Girdiler
Y_ζ	: Yeni çıkış boyutu
z_1	: Çok katmanlı algılayıcı çıkış özellik haritası
M_j	: Girdi harita seçimi
b_j^l	: Eğitilebilir ek bias
c_{in}	: Giriş kanallarının sayısı
c_{out}	: Sonuç kanallarının sayısı
k_{ij}^l	: Evrişim çekirdeği
w_1	: Ağırlık parametresi
x_i^l	: Çıktı özellik haritası
x_i^{l-1}	: Önceki katmanların özellik haritası
$\ \cdot\ $	: Öklid mesafesi
$B(\cdot, \cdot)$	: Sınır terimi
C	: Girdi görüntü derinliği
cb	: Filtre boyutu
cs	: Evrişim işleminde kullanılan filtre sayısı
$E(\cdot)$	: Ortalama
$H(x)$	: Artık blok çıktısı
H_i, h_i	: Girdi görüntü yüksekliği
L	: piksel kümesi
p, q	: Görüntüdeki piksellerin oluşturduğu iki farklı bileşen çiftleri

$R(.,.)$	: Bölgesel terim
S	: Görüntünün üzerinde hareket ettirilen adım sayısı
$V(.)$	: Varyans
W_i, w_i	: Girdi görüntü genişliği
X	: Batch normalizasyonun katmanına giriş
y	: Veri noktasının sınıfı
A	: Adım genişliği
γ, β	: Öğrenilebilir parameter
σ	: Sigmoid
$\Phi(.)$	: Lineer olmayan bir operatör
e	: Hata parametresi
$f(.)$	: Aktivasyon fonksiyonu
j	: Amaç fonksiyonu
ϵ	: Sayısal kararsızlık için eklenmekte olan sabit

Kısaltmalar

(k-NN)	: K-En yakın komşu
AUC	: ROC eğrisi altındaki alan
B-ESA	: Bölgesel evrişimli sinir ağı
BN	: Batch normalizasyon
BT	: Bilgisayarlı tomografi
CAD	: Bilgisayar destekli tanı
Cds	: Derinlemesine ayrılabilir evrişimler
CIR	: Kontrast iyileştirme oranı
ConvLSTM	: Evrişim operatörlü uzun kısa süreli bellek
CPU	: Merkezi işlem birimi
Cs	: Standart evrişimler
ÇG-DESAT	: Derin evrişimsel sinir ağı topluluğu
DBMs	: Derin boltzmann makineleri
Dconv	: Derinlik yönünden evrişim işlemi
DCT	: Ayrık kosinüs dönüşümü
DHB-ESA	: Daha hızlı bölgesel evrişimli sinir ağları
DVM	: Destek vektör makineleri
E	: Entropi
ESA	: Evrişimsel sinir ağı
FC	: Tam bağlı katman
GIU	: Grafiksel işleme ünitesi
GK	: Graf kesim
GPU	: Grafik işlemci birimi
HB-ESA	: Hızlı bölgesel evrişimli sinir ağı
HSTR	: Histogram germe
IAN	: Alt alveoler siniri
IoT	: Nesnelerin interneti
IoU	: Birleşim üzerinde kesişme oranı
KA	: Karar ağaçları
KIBT	: Konik ışınli bilgisayarlı tomografi
KOSGEB	: Türkiye küçük ve orta ölçekli işletmeleri geliştirme kurumu
LSTM	: Uzun kısa süreli bellek

M3	: Alt üçüncü azı dişi
mAP	: Genel ortalama kesinlik
Max-flow	: Maksimum akış
Min-cut	: Minimum kesim
MLP	: Çok katmanlı algılayıcı
MRI	: Manyetik rezonans görüntüleme
MSA	: Çok başlı öz dikkat
NB	: Naïve bayes
OCT	: Optik koherens tomografi
PCA	: Temel bileşenler analizi
Pconv	: Noktasal evrişim işlemi
RBF	: Radyal tabanlı fonksiyonlar
ReLU	: Doğrultulmuş lineer birim
ROC	: Alıcı işlem karakteristiği
ROI	: İlgi alanı havuzu
RPN	: Bölge öneri ağı
RT	: Radon dönüşümü
S	: Nesne
SAHE	: Keskin uyarlanabilir histogram eşitleme
SCLAHE	: Keskin kontrast uyarlanabilir histogram eşitleme
SF	: Uzamsal frekans
SMAHE	: Keskin medyan uyarlanabilir histogram eşitleme
SW-MSA	: Kaydırılmış pencere tabanlı çok başlı öz dikkat
T	: Arka plan
TI	: Yakın kızılötesi transillüminasyon
ViT	: Vision transformatör
VRF	: Vertikal kök kırığı
W-MSA	: Pencere tabanlı çok başlı öz dikkat
YSA	: Yapay sinir ağları

1. GİRİŞ

Görüntüleme teknikleri sağlık sektöründe gün geçtikçe büyüyen önemli bir araştırma alanı olmak ile birlikte tarım, gıda endüstrisi, astronomi ve jeoloji gibi daha birçok alanı kapsayan disiplinler arası bir konudur. Tıbbi görüntüleme teknolojisindeki gelişmeler neticesinde sağlık taramaları ve hastalık tespitleri için önemli bir adım oluşturmıştır. Teknolojideki ilerlemeler ile birlikte uzmanların hastalık tespitindeki hassasiyetini ve erken teşhis olanaklarını arttırarak, hastalığın erken aşamasında uygun tedaviyi alma olanağı sağlanabilmektedir. Tıbbi görüntüleme sadece ilk tanıda değil aynı zamanda hastalığın tedaviye nasıl tepki verdiğini, hastalığın bu süreçte ne kadarlık ilerlediğini ve bir tedavi planının ne zaman durdurulabileceğini izlemek içinde gerekli görülmektedir.

Genel itibariyle ağız içerisindeki hastalıkların tanımlanması, tedavi süreci ile önlenmesini kapsayan diş hekimliği hizmeti sağlık alanında en hızlı büyüyen sektörlerden birisidir. Bütün sağlık alanlarında olduğu gibi diş hekimliğinde de teşhis ve tespitte tıbbi görüntüleme işlemi çok büyük bir önem arz etmektedir. Dijital radyografisi diş hekimliğinde yaklaşık olarak 25 yıldan uzun bir süredir faaliyet göstermek ile birlikte gelişen görüntüleme teknik cihazlarının kullanımı giderek yaygınlaşmaktadır. Gelişen teknoloji ile kullanılan bu cihazlar tedavide ve teşhiste elde edilen sonuçların daha iyi olmasını sağlamaktadır. Diş radyografisi dişin yapısını ve ağızdaki konumlarını gösteren ağız ve diş sağlığı için kullanılan bir görüntüleme türüdür. Radyografiler, x ışınları aracılığı ile vücuda nüfuz ederek hava içeren yapılar siyah, diğer ağızdaki dişler, doku ve sıvı gri tonlarında görüntülenmesi sağlanır [1].

Günümüzde diş hekimliği, diş görüntüleme teknolojilerinin kullanımıyla daha doğru teşhisler koyma imkânı elde etmiştir. Özellikle, dijital görüntüleme teknolojileri sayesinde diş hekimleri, hastalarının diş sağlığına daha kapsamlı bir bakış açısıyla yaklaşabilmektedir. Diş görüntüleme sistemleri sayesinde, dişlerin yüzeyindeki küçük çatlaklar ve çürükler gibi problemler daha erken aşamada tespit edilebilmektedir. Ayrıca, dişlerin içerisindeki kanalların tedavisi sırasında ve sonrasında dişin durumunu izlemek de mümkündür. Geleneksel yöntemlerle tespit edilemeyen diş yapısındaki bozulmalar da dijital görüntüleme teknolojileri ile kolaylıkla görülebilir. İmplant uygulamalarında öncesinde durum belirleme ve ardından gelen tedavi sürecinin gözlemlenmesi gibi birçok alanda diş görüntüleme teknolojilerinin kullanımı artmaktadır. Bilgisayarlı Tomografi (BT), Ultrasonografi, Panoramik Görüntüleme ve Manyetik Rezonans Görüntüleme (MRI) gibi tanı yöntemleri, diş hastalığı enfeksiyonlarının tiplerinin doğrulanmasında yardımcı olmaktadır. Bu sayede, diş hekimleri daha kesin teşhisler koyarak, hastalarının tedavi süreçlerinde daha başarılı sonuçlar elde etmekte ve hastaların diş sağlıklarını daha etkili bir şekilde korumaktadır [2,3].

Dijital görüntüleme teknolojisiyle birlikte, diş kliniklerinde dijital radyografi makineleri popüler hale gelmektedir. Bu makineler, geleneksel radyografilere göre sadece yarısı kadar radyasyon dozu kullanarak, karşılaştırılabilir kalitede diş röntgenleri elde edebilmektedirler. Dijital radyografler, sonuçların monitör üzerinde anında incelenebilmesi nedeniyle film çıktısına ihtiyaç duymamaktadır. Eğer alınan görüntü yeterince iyi değilse, uzmanlar hızlıca yeni bir görüntü alabilmektedirler. Bu nedenle, genellikle hastaların dijital kayıtlarındaki diş röntgenleri geleneksel röntgenlere göre daha yüksek görüntü kalitesine sahiptir. Dijital radyograflerin saklanması ve işlenmesi de daha kolaydır. Ayrıca, çevre dostu olması gibi birçok avantajı bulunmaktadır. Tüm bu sebeplerden dolayı, dijital radyografi makineleri diş hekimliğinde tercih edilen bir teknoloji haline gelmektedir [4,5].

Dördüncü Sanayi Devrimine giriş yapmakta olan dönemde büyük veri, Nesnelerin İnterneti (IoT), ve yapay zeka gibi alanlarda teknolojik yenilikler gün geçtikçe artmaktadır [6]. Gelişmekte olan ülkelerde radyografi görüntülerinin yapay zeka ile otomatik analizi giderek daha önemli hale gelmektedir. Bu yüzden yapay zeka uygulamaları klinik tıpta büyük ilgi görmektedir. Bilgisayar Destekli Tanı (CAD) sistemleri ile kanser tespitleri, beyin bölgesindeki lezyonların lokasyonu, çeşitli bölgelerdeki hastalıkların sınıflandırılması gibi tıbbi problemler üzerinde uygulamalar gerçekleştirilmiştir. Derin öğrenme, makine öğrenmesi ve yapay zeka alanlarının altında yer alan bir teknoloji olarak son yıllarda tıbbi alanda oldukça popüler hale gelmiştir. Medikal alanda kullanılan görüntüleme sistemleri, hastalık teşhisi, tedavi planlaması ve diğer birçok alanda derin öğrenme algoritmalarının kullanımı yaygınlaşmaktadır. Derin öğrenmenin medikal alanda kullanımı, büyük ölçüde yüksek öğrenme yeteneğine dayanmaktadır. Bu teknoloji, büyük veri kümeleri üzerinde çalışarak öğrenme sürecini gerçekleştirir ve sonuçta verileri analiz ederek hastalıkların teşhis edilmesi ve tedavi planlamasına yardımcı olmaktadır. Derin öğrenme teknikleri, özellikle radyoloji alanında dijital görüntüleme sistemlerinin gelişmesiyle birlikte oldukça önemli bir yere sahip olmuştur. Günümüzde, derin öğrenme algoritmaları kullanılarak, tıbbi görüntülerdeki anormalliklerin tespiti, meme kanseri taraması, kardiyovasküler hastalıkların teşhisi, nörolojik bozuklukların teşhisi gibi birçok alanda başarılı sonuçlar elde edilmiştir. Bu sistemler sayesinde hastalıkların erken teşhis olanaklarını ve hassasiyet seviyelerini arttırarak uzmanlara zaman kazandırmakla birlikte hastanın daha iyi tedavi edilebilmesi sağlanabilmektedir.

Diş hekimliği alanında radyografi görüntülerindeki tanı sistemlerinde önemli bir araştırma konusu haline gelmiştir. Bu alandaki ilk çalışmalar diş radyografi görüntülerinin iyileştirilmesi üzerine başlamıştır. Diş radyografisi uygulamalarında insan sağlığında tehlike oluşturmaması için minimum düzeyde kullanılan radyasyon dozu çok gürültülü, düşük kontrastlı ve koyu röntgen görüntülerine neden olmaktadır. Görüntü kalitesinde oluşan bu olumsuzluklar görüntü iyileştirme teknikleri ile geliştirilmektedir. Çalışmalarda kullanılan filtreler ve önerilen yöntemler sayesinde dijital radyografi görüntülerinin tanısallık performansını arttırdığı gözlemlenmiştir [2]. Son yıllarda

literatürdeki çalışmalar sadece diş röntgenlerinin elde edilmesinde görüntü kalitesinin artırılması değil aynı zamanda diş hastalıklarının tespiti, diş materyallerinin tespiti, maksiller sinüs enfeksiyonu tespiti, yaş ve cinsiyet teşhisi gibi birçok yönde çalışmalar gerçekleştirilmektedir.

1.1. Literatür İncelemesi

Bu bölümde, diş röntgen görüntülerinin iyileştirilmesi, otomatik olarak hastalık ve materyal tespiti ile ilgili literatürde yapılan çalışmalar alt başlıklarda kapsamlı bir şekilde incelenmiştir.

1.1.1. Görüntü Kontrastının Geliştirilmesine Yönelik Çalışmalar

Elde edilen görüntünün kaliteli olması, uzaman kişinin doğru yorumlanması için önemli bir kriterdir. Kontrast artırma teknikleri diş hekimlerinin radyografi görüntülerini daha iyi değerlendirmesine yardımcı olmakla kalmaz, aynı zamanda derin öğrenmeye dayalı diğer daha gelişmiş otomatik tanımlama şemalarının ön işlemesi olarak da kullanılır. Literatürde diş röntgen görüntüleri için kontrast ve detay iyileştirme algoritmaları şu şekildedir;

Román ve arkadaşları panoramik radyografide kontrast ve detay iyileştirmesi ile görsel kalitenin artırılması üzerine bir çalışma gerçekleştirmişlerdir. Önermiş oldukları Çok Ölçekli Top-Hat Dönüşümü (MSTHGR) olarak adlandırılan algoritmanın Kontrast İyileştirme Oranı (CIR), Entropi (E) ve Uzamsal Frekans (SF) performans metriklerine göre en iyi sonuçları aldığını gözlemlemişlerdir. Ayrıca algoritmalarla elde edilen görsel sonuçlar klinik olarak uzman diş hekimleri tarafından değerlendirilmiştir [7].

Ahmad ve arkadaşları hastalık tespitine yönelik oluşturmuş oldukları diş görüntülerinin iyileştirilmesi üzerine bir çalışma gerçekleştirmişlerdir. Görüntüler Keskin Uyarlanabilir Histogram Eşitleme (SAHE), Keskin Medyan Uyarlanabilir Histogram Eşitleme (SMAHE) ve Keskin Kontrast Uyarlanabilir Histogram Eşitleme (SCLAHE) gibi geliştirme teknikleri kullanılarak gözlemlenmiştir. Genel sonuçlara bakıldığında SCLAHE'nin orijinal görüntü üzerindeki diş anormalliklerin görünümünü önerilen diğer iki bileşik algoritmadan daha iyi performans gösterdiği görülmüştür [8].

Simon ve arkadaşları diş röntgen görüntülerindeki ön işlem aşaması üzerine bir çalışma gerçekleştirmişlerdir. Uyarlanabilir histogram eşitleme, morfolojik güçlendirme ve dalgacık ile gürültü giderme birleşimi ile yeni bir ön işlem yaklaşım geliştirdiler. Önerilen yöntem mevcut gösterilen diğer yöntemlerden daha iyi sonuçlar elde edildiği gözlemlenmiştir [9].

Kaur ve arkadaşları çoklu morfolojik gradyan yöntemi kullanılarak panoramik diş radyografilerinin kenar tespitinde daha keskin ve net görüntüler oluşturulması sağlanmıştır [10].

Naam ve arkadaşları panoramik diş röntgen görüntüsünde uzman kişilerin çürük tanımlanmasını kolaylaştırmayı ve doğruluğunu arttırmayı amaçlanmıştır. Kırpma, morfoloji

genişleme ve morfoloji aşınması gibi görüntü işleme tekniklerinde genel olarak bilinen yöntemlerin yanı sıra çoklu morfoloji gradyan algoritması geliştirilmiştir. Geliştirilen ön işlem aşaması ile diş röntgen görüntüsünü daha iyi netleştirerek çürük tespitini kolaylaştırmıştır [11].

Obuchowicz ve arkadaşları çürük tespitinde belirli doku özellik haritası çıkarma yöntemleri kullanarak karşılaştırma yapmışlardır. Orijinal görüntülere Histogram Germe (HSTR) algoritması uygulanarak bir ön işlemden geçirilmiştir. Uygulanan doku özellik haritaları yöntemlerinde yapılan karşılaştırma sonucunda en yararlı bilginin enerji parametresi kullanılarak sağlandığı gözlemlenmiştir. Ayrıca analizlerde çürükten etkilenen bölgelerin görselleşmesinde entropinin de iyi bir performans gösterdiği belirtilmiştir [12].

Naam ve arkadaşları çalışmalarında uzmanların proksimal çürükleri belirlenmesinde röntgen görüntülerinin kalitesini iyileştirmeyi amaçlamaktadır. Oluşturdukları veri setinde 27 adet proksimal diş çürüklerini içeren diş röntgen görüntüleri bulunmaktadır. Önerilen çoklu morfolojik gradyan yöntemi ile net görüntüler üretilerek nesnelerin kenarları netleştirilmiştir. Sonuçlar gözlemlendiğinde proksimal çürükleri ve ilerleme seviyesini uygun şekilde tanımlamak için kullanılabilir [13].

1.1.2. Çürük Tespitine Yönelik Çalışmalar

Panoramik ve periapikal görüntüleme tekniklerine dayalı çürük tespiti, diş hekimleri tarafından manuel yapılmaktadır. Radyografide görülen çürük dişin teşhisi çoğu zaman doğru şekilde yapılamamaktadır. Bu hekimin yeni mezun olması ya da yoğun hasta bakması nedeniyle var olan diş çürüğü gözden kaçmaktadır. Bu durum, çürüğün ilerlemesi, ileri diş enfeksiyonlarına ve dişin kaybedilmesine neden olabilmektedir. Bu olumsuzlukların yaşanmaması ve diş hekimlerine kolaylık sağlanması amacı ile makine öğrenmesi ve görüntü işleme tekniklerine dayalı geliştirilen otomatik sistemler, büyük bir önem kazanmıştır. Literatürde çürük tespitine yönelik çalışmalar şu şekildedir;

Geeth ve arkadaşları laplace filtreleme, pencere tabanlı uyarlanabilir eşik ve geri yayımlı sinir ağı tabanlı bir sistem önermişlerdir. Birkaç istatistiksel özellik çıkarımından elde edilen öznitelikler, geri yayımlı bir sinir ağı tarafından sınıflandırılır. Periapikal 105 adet diş röntgeni görüntüleri kullanılarak çürük tespitinde %97.1 doğruluk sağlanmıştır [14].

Prajapati ve arkadaşları, 251 periapikal diş röntgeninde önceden eğitilmiş VGG16 modeline dayalı bir transfer öğrenme yaklaşımı kullandı. 3 farklı sınıf için yapılan çalışmada tam eğitilmiş ağ mimarisine ait çürük görüntülerinde % 87.5 doğruluk sonucu elde edilmiştir [15].

Singh ve Sehgal çalışmalarında, Radon Dönüşümü (RT) ve Ayrık Kosinüs Dönüşümü'ne (DCT) dayalı otomatik bir çürük tespit sistemi önermektedir. Seçilen özellikler Temel Bileşenler Analizi (PCA) tekniği kullanılarak çıkarıldı. Son olarak rastgele orman sınıflandırıcısına uygulanmış ve %86 doğruluk elde edilmiştir [16].

Casalegno ve arkadaşları Yakın Kızılötesi Transillüminasyon (TI) görüntüleme teknolojisi ile elde edilen diş görüntülerindeki çürüklerin tespiti için bir yöntem önermişlerdir. Önerilen Evrişimsel Sinir Ağı (ESA) mimarisi ile oklüzal ve proksimal çürük lezyonları için sırasıyla %83.6 ve %85.6'lık bir AUC performans alanı elde edilmiştir [17].

Cantu arkadaşları 3686 bitewing radyografisinde çürük lezyonlarının tespiti üzerine bir çalışma gerçekleştirmiştir. Diş çürüklerinde UNet mimarisi kullanılmıştır. Önerilen sinir ağı %80 doğruluk göstermiştir [18].

Datta ve arkadaşları nötrozofik etki alanı tabanlı özel bir öznetelik kullanıldı. Önerilen bu öznetelik çıkarma yöntemi belirli özelliklerin birleştirilmesi ile elde edilmiştir. Aktif kontur tekniği kullanılarak 120 adet periapikal röntgen görüntüsünden çürükler tespit edilmiştir. Yapılan deneysel çalışmalar sonucunda ortama olarak doğruluk başarımı %92'nin üzerindedir [19].

Son ve arkadaşları çalışmalarında bölütleme, sınıflandırma ve karar verme aşamasından oluşan hibrit bir yaklaşım önermişlerdir. Yarı-denetimli bulanık kümelemeye dayalı bir bölütleme yöntemi kullanılmıştır. Ayrıca yeni bir grafik tabanlı kümeleme tekniği ile sınıflandırma gerçekleştirilmiştir. Çürük de bulunan 5 farklı sınıf için önerilen yöntemin doğruluğu %90 olarak gözlemlenmiştir [20].

Lakshmi ve Chitra, 1700 panoramik diş röntgen görüntüsü kullanılarak çürük tespiti için bir çalışma gerçekleştirmişlerdir. Geleneksel bölütleme teknikleri ve derin ESA mimarisi ile başarımları karşılaştırılmıştır. Elde edilen sonuçlar gözlemlendiğinde grafik kesim ve derin ESA yöntemi ile %98.6'lık bir doğruluk sağlanmıştır [21].

Oprea ve arkadaşları mevcut olan çürük lezyonunun ne boyutta olduğunu incelemek ve daha sonrasında diş radyografisinde bulunan çürük tipini sınıflandırılması üzerine bir yöntem önermişlerdir. Röntgende dişin kenar algılama yöntemi kullanılarak bölütleme gerçekleştirilmiştir. Daha sonra diş üzerindeki etkilenen çürük piksellerinin sayısı (siyah bölge) belirlenerek boyutlarına göre sınıflara ayrılan bir çalışma gerçekleştirmişlerdir [22].

Lee ve arkadaşları periapikal diş röntgen görüntülerinden diş çürüklerinin tespitinde GoogLeNet ve Inception v3 ESA mimarisi kullanmışlardır. Önerilen çalışmada 3000 görüntüden oluşan periapikal veri seti 2400 adet eğitim için ve 600 adet test için kullanılmıştır. Elde edilen sonuçlarda premolar, molar ve hem premolar hem de molar diş çürüğü modellerin doğruluk oranı sırasıyla %89, %88 ve %82 olarak gözlemlenmiştir [23].

Megalan Leo ve Reddy yapay sinir ağı ve ESA tekniklerinden oluşan hibrit bir model önermiştir. Deneysel çalışmalarda 300 eğitim ve 180 test diş röntgeni görüntüsü kullanmışlardır. Önerilen sistem, diş çürüğü sınıflandırmasında %96 doğruluk sağlamıştır [24].

Huang ve Lee, farklı bir görüntüleme tekniği olarak Optik Koherens Tomografi (OCT) görüntülerini kullanarak çürük tespiti üzerine bir çalışma gerçekleştirdiler. 63 OCT diş görüntüsünden kırpma işlemi kullanılarak toplam 748 tek diş görüntüsü çıkarıldı. Farklı ESA

mimarileri temel alınarak gerçekleştirilen deneysel çalışmalarda 599 adet görüntü eğitim, geri kalanı ise test amaçlı kullanılmıştır. Sonuç olarak ResNet-152 mimarisi ile %95.21 doğruluk oranı elde ettiler [25].

Bui ve arkadaşları derin ve geometrik özellikler kullanan Destek Vektör Makinesi (DVM) sınıflandırıcısına dayalı çürük tespiti için hibrit bir model önerdi. Deneysel çalışmalarda 229 adet çürük ve 304 adet çürük olmayan (sağlıklı) görüntü kullanmışlardır. Sonuç olarak önerilen sistemin doğruluğu %91.7 olarak elde edilmiştir [26].

Majanga ve Viriri, morfolojik yöntemlere ve derin öğrenmeye dayalı bir sistem geliştirdi. Ön işleme aşamasında gauss bulanıklığı filtreleri ile eşikleme yöntemleri kullanılarak diş görüntülerinin sınırları belirlenmiştir. Daha sonra diş görüntülerinin (çürük/çürük olmayan) sınıflandırılması, derin öğrenmeye dayalı olarak elde edilen öznetelikler ile belirli bir eşik değeri kullanılarak yapılmıştır. Periapikal diş röntgeni görüntülerine dayalı veri artırma yöntemleri kullanılarak elde edilen 11.114 diş görüntüsünü kullandılar. Sonuç olarak, çürük tespiti için önerilen model %97 doğruluk değeri ile başarılı olmuştur [27].

Vinayahalingam ve arkadaşları panoramik x-ray görüntüleri kullanarak derin öğrenme mimarilerinin sınıflandırma performansının değerlendirilmesine dayalı bir çalışma gerçekleştirmiştir. ESA mimarilerini eğitmek için 400 kırılmış panoramik röntgen görüntüsü kullanıldı. Deneysel çalışmalarda MobileNetV2 mimarisi ile %87 doğruluk elde ettikleri görülmüştür [28].

1.1.3. Maksiller Sinüs Tespitine Yönelik Çalışmalar

Maksiller sinüs diş köklerinin ilişkili olması nedeni ile dişlerdeki herhangi bir enfeksiyondan etkilenmektedir. Literatürde maksiller sinüs tespiti üzerine çalışmalar şu şekildedir; Jung ve arkadaşları lezyon ve hava olarak ayırmayı amaçlayan maksiller sinüs bölütleme üzerine bir çalışma gerçekleştirmişlerdir. Konik Işınlı Bilgisayarlı Tomografi (KIBT) görüntülerine özelleştirilmiş 3D nnU-Net mimarisi uygulanmıştır. Sınırlı sayıdaki verilerin hem etiketleme işlemini azaltmak hem de başarımın artırılması için 3 adımdan oluşan aktif bir öğrenme yöntemi uygulanmıştır. Önerilen yöntemdeki adımlarda kendinden bir önceki eğitilen modeli kullanarak otomatik olarak özellik çıkarımı yaparken, sınırlı eğitim veri kümeleriyle modelin performansını iyileştirmek için adım başına yeni hacimler eklemektedir. Elde edilen sonuçlarda 3D U-Net mimarisinin tıbbi görüntü işlemede iyi sonuçlar vereceği gözlemlenmiştir [29].

Mori ve arkadaşları panoramik diş röntgen görüntülerinden maksiller sinüs tespiti üzerine bir transfer öğrenme yöntemi kullanmışlardır. Kaynak model A kurumundan alınan 350 panoramik görüntüden oluşmaktadır. B kurumundan alınan 25, 50, 100, 150 ve 250 panoramik eğitim verileri kaynak modele eklenmesi ile 5 farklı hedef modeli oluşturulmuştur. Yapılan çalışmalar sonucunda 25 eğitim görüntüsüne (T25) sahip hedef model, 50 eğitim görüntüsünün (T50) eklenmesiyle

maksiller sinüs tespitinde diğer uygulamalarına oranla daha iyi başarımlar gösterdiği gözlemlenmiştir [30].

Murata ve arkadaşları maksiller sinüs için 400 adet sağlıklı ve 400 adet iltihaplı panoramik röntgen görüntülerinden oluşan bir veri seti kullanmışlardır. Veri artırma yöntemi ile her bir kategori 6000 örnek olacak şekilde yükseltilmiştir. AlexNet mimarisinin 5 evrim katmanı ve 3 tam bağlı katmanı kullanılarak oluşturulan derin mimaride %87.5'lik bir doğruluk elde etmişlerdir [31].

Kim ve arkadaşları 2.430 normal ve maksiller sinüs deneğini içeren hastadan elde edilen görüntüler üzerine bir çalışma gerçekleştirmiştir. Veri setinin %70'i eğitim olarak ayrılan çalışmada, VGG 16, VGG-19 ve ResNet-101 algoritmaları uygulanmıştır. Üç farklı mimariden elde edilen sınıflandırma sonuçları çoğunluk karar algoritması ile birleştirilmiştir. Önerilen yöntemin doğruluk sonucu %94.1 olarak bulunmuştur. Bu çalışmada lezyon bölgesinin bölütlenmesi için çoğunluk karar algoritması kullanılarak bireysel ESA modellere kıyasla daha yüksek başarımlar olduğu gözlemlenmiştir [32].

Kuwana ve arkadaşları 587 adet sağlıklı (sınıf 0), 416 adet iltihaplı (sınıf 1) ve 171 adet kist (sınıf 2) görüntülerinden oluşan etiketli bir maksiller sinüs veri seti hazırladılar. Veri seti; eğitim, test 1 ve test 2 olarak 3 farklı kategoriye bölündü. Önerilen DetectNet mimarisi ile maksiller sinüs tanısında sırasıyla %90 (test 1) ve %91 (test 2) doğruluk gözlemlenmiştir [33].

Kim ve arkadaşları 9000 adet diş röntgen görüntülerinden normal ve maksiller sinüs olacak şekilde sınıflandırdılar. Oluşturulan veri setinde 8000 adet görüntü ayrılarak geliştirilen derin mimariye eğitim olarak kullanılmışlardır. Tanımlanan iki ayrı test seti için performans analizi yaptılar. Önerilen yöntemin Alıcı İşlem Karakteristiği (AUC) performans başarısı sırası ile %93 ve %88 olarak gözlemlendiler [34].

Ohashi ve arkadaşları maksiller sinüs için 49 adet sağlıklı ve 49 adet sinüzitli panoramik röntgen görüntüsünden oluşan bir veri seti kullanmışlardır. Toplamda 98 panoramik diş röntgen görüntüsü, 12 deneyimsiz diş hekimi ve 4 uzman oral radyolog tarafından gözlemlendi. Ortak bir araştırma projesinde geliştirilen CAD sistem ile %73.5'lik bir doğruluk elde etmişlerdir [35].

1.1.4. Gömülü Diş Tespitine Yönelik Çalışmalar

Gömülü dişler her yaşta görülebilen, ilerleyen aşamalarda diş çürümesine, kök rezorpsiyonuna ve ağrıya neden olan yaygın bir sorundur. Gömülü diş tespitine yönelik sınırlı sayıda çalışma bulunmaktadır. Bunlar;

Orhan ve arkadaşları gömülü üçüncü azı dişleri tespit edilmesi üzerine çalışma gerçekleştirmişlerdir. Çalışmada 65 hastaya ait 130 gömülü üçüncü azı dişi kullanılmıştır. ESA sistemine dayalı olarak gerçekleştirilen uygulamada; %86,2 gömülü, %78.6 kök sayısı, %68.1 kanal sayısı doğru olarak tespit edilmiştir [36].

Faure ve arkadaşları ResNet 101 ve Faster RCNN kullanarak gömülü dişlerin tespiti için bir model önermişlerdir. 530 adet panoramik diş röntgen görüntüsü kullanılan çalışmada %51.7 ile %88.9 arasında değişen doğruluk gözlemlenmiştir [37].

Kuwada ve arkadaşları panoramik radyograflerde üst kesici diş bölgesinde gömülü süpernümerer dişlerin varlığını tespit etmek ve sınıflandırmak için derin öğrenme sistemleri geliştirdi. Bu sistemlerde üç öğrenme modeli kullanılmıştır: AlexNet, VGG-16 ve DetectNet. Bu modeller, 275 hastadan elde edilen 550 panoramik radyografi görüntüsü kullanılarak test edilmiştir. Deneysel sonuçlarda, önerilen DetectNet en yüksek doğruluk değeri olan %96'yı elde ettiler [38].

Zhang ve arkadaşları gömülü üçüncü azı diş çekimi ameliyat sonrası oluşan yüz şişmesinde yapay sinir ağının tahmin doğruluğunu değerlendirmişlerdir. 400 hastadan oluşan veri seti, geliştirilmiş eşlenik grads BP algoritması ile eğitim ve test edilmiştir. 5 kat çaprazlama doğruluğu kullanılan uygulamada %98 doğruluk elde edilmiştir [39].

Başaran ve arkadaşları R-CNN Inception V2 modeli kullanılarak on farklı diş durumun değerlendirilmesi üzerine bir çalışma gerçekleştirmişlerdir. Oluşturdukları veri setinde 1084 panoramik görüntüde 796 adet gömülü diş içermektedir. Önerilen yöntem sonucunda gömülü diş için %86.25 F1-skoru performans başarımları elde edilmiştir [40].

Celik, 300 hastadan elde edilen 440 adet panoramik diş röntgen görüntüsü kullanılarak gömülü diş tespiti üzerine derin bir mimari önermiştir. Sistem Faster RCNN ve YOLOv3 olmak üzere iki dedektörün analizini içermektedir. Faster RCNN'de özellik çıkarıcı omurga olarak ResNet50, AlexNet ve VGG16 kullanılmıştır. Yapılan deneysel çalışma sonucunda Genel Ortalama Kesinlik (mAP) %96 olarak YOLOv3'ün gömülü mandibular üçüncü azı diş tespiti için daha yüksek performans gösterdiği gözlemlenmiştir [41].

Ayrıca literatürde kök kırığı tespiti, mandibular üçüncü azı dişi ve mandibular kanal tespiti, üçüncü azı dişi gelişim evrelemesi ile yaş tahmini ve lezyon ile ilgili tespit çalışmaları yapılmıştır. Fukuda ve arkadaşları panoramik radyografi görüntülerinde Vertikal Kök Kırığı (VRF) tespitinde yapay zeka sistemlerinin kullanılabilirliğini değerlendirmeyi amaçlamaktadır. DetectNet ve DIGITS sürüm 5.0 kullanılarak VRF tespiti için bir ESA tabanlı derin öğrenme modeli oluşturmuşlardır. 5 kat çapraz doğrulama kullanılan sistemde, kök kırıklarını tespit etme konusunda oldukça yüksek bir hassasiyete sahip olduğunu gözlemlemişlerdir [42]. Vinayahalingam ve arkadaşları UNet tabanlı bir derin öğrenme yaklaşımı ile üçüncü azı dişlerinin ve mandibular sinirin otomatik tespiti üzerine bir çalışma gerçekleştirmişlerdir. Alt alveoler sinirin (IAN) alt üçüncü azı dişlerin (M3) ortalama zar katsayıları sırasıyla 0.947 ± 0.033 ve 0.847 ± 0.099 olarak bulunmuştur. Derin öğrenmenin, üçüncü azı dişleri ve mandibular sinirin tespitinde doğruluğu artırabileceğini ve cerrahi planlamada yardımcı olabileceğini göstermiştir [43]. Üçüncü azı gelişiminin evrelendirilmesi, alt yetişkinlerde yaş değerlendirmesi için sıkça kullanılan bir yöntemdir. Banar ve arkadaşları çalışmalarında önerdikleri derin öğrenme yöntem ile üçüncü azı dişlerin ortalama

olarak %93 ortalama zar katsayılar ile bölütleme başarımları elde etmişlerdir [44]. Ekert ve arkadaşları apikal lezyonların tespiti için 7 katmanlı bir derin sinir ağı ve 10 kat çapraz doğrulama yönteminin kullanıldığı bir yöntem önermişlerdir. 2001 diş segmentinin kullanıldığı çalışmada yüksek özgüllük ve orta düzeyde hassasiyet elde edilmiştir [45]. Tajima ve arkadaşları panoramik diş röntgen görüntülerinde derin öğrenmeyi kullanarak, çenelerin kist benzeri radyolüsent lezyonlarını tespit edebilen transfer öğrenmeye dayalı bir model önermişlerdi. Önerdikleri ESA modelinde %98.3 oranında bir doğruluk elde etmişlerdir [46].

1.2. Önerilen Sistemin Genel Çerçevesi

Panoramik ve periapikal görüntüleme tekniklerine dayalı diş hastalıkları ve materyal tespitlerinde diş hekimleri tarafından manuel yapılmaktadır. Çok sayıda hasta ile karşı karşıya kalan halk sağlığı merkezlerinde teşhis ve tedavi süreçleri çok zaman almak ile birlikte gözden kaçan durumlar oluşmaktadır. Bunun ile birlikte radyografilerin yorumlanması diş hekiminin deneyimine bağlı olarak değişebilmektedir. Diş hastalıklarının tespiti, erken tedavi süresince önemli bir rol oynamaktayken ortodonti gibi radyoloji uzmanlığında, radyolog eksikliği daha da belirgin bir haldedir. Bu yüzden diş hekimliği alanında radyografi görüntülerindeki tanı sistemleri de önemli bir araştırma konusu haline gelmiştir. Araştırmacılar bu sorunun çözümü için diş panoramik radyografilerin otomatik olarak analiz edilmesi üzerine çalışma gerçekleştirmektedir. Bu sayede diş hekimlerine klinik karar vermede yardımcı olabilir, zamandan tasarruf edebilir ve olumsuzlukları azaltabilir. Bu tez çalışmasında otomatik diş materyali ve hastalıkları tespiti için özgün derin öğrenme tabanlı modeller geliştirilmiştir. Bu bölümde tez çalışmasının amaçları, çıktıları ile birlikte otomatik hastalık ve materyal tespiti konusunda geliştirilen sistemin Ar-Ge niteliği, yenilikçi yönü ve son olarak tez çalışmasının organizasyonu hakkında bilgiler sunulmuştur.

1.2.1. Tezin Amacı

Bu tez çalışmasının temel amacı diş röntgen görüntülerinde hastalık ve materyal tespiti için derin öğrenme tabanlı yeni yöntemlerin ve algoritmaların geliştirilmesidir. Bu amaç doğrultusunda önerilen yöntemlerin kullanıldığı sistemler sayesinde hem diş hekiminin yükü azaltılarak hem de ağız ve diş sağlığı açısından kalitenin artması sağlanacaktır. Ayrıca literatürde, kamuoyuna erişime açık veri setlerinin yetersiz olması bu tez çalışmasının gereksinimine gerek duyulmuştur. Diş röntgen görüntülerinin uzman bir diş hekimi tarafından etiketlenerek veri seti dâhilinde çalışma gerçekleştirilecektir. Elde edilen bu özgün veri setleri diş hekimliği alanında çalışmak isteyen araştırmacılara kolaylıklar sağlayacaktır.

1.2.2. Tezin Çıktıları

Literatürde mevcut olarak bulunan diş röntgen görüntüleri kullanılarak gerçekleştirilen makine öğrenmesi tabanlı yöntemler kapsamlı bir şekilde incelenmiş ve bu yöntemlerin belirli (güçlü ve zayıf) yönleri ortaya çıkarılmıştır. Bu tez çalışmasında, otomatik diş röntgen görüntülerinde hastalık ve materyal tespiti için derin öğrenmeye dayalı özgün ve güncel yöntemler geliştirilmiştir. Buna ek olarak literatürde açık erişimli veri seti yetersizliğinden dolayı özgün veri setleri oluşturulmuştur. Önerilen modeller mevcut güncel modeller ile karşılaştırılarak daha yüksek performansta başarımlar sonuçları elde edilmiştir. Yapılan çalışma ile ilgili olarak makaleler hazırlanmıştır. Tez süresince uluslararası Science Citation Index Expanded indeksli dergilerde dört adet makale yayınlanmıştır.

- A. Imak, A. Çelebi, M. Türkoğlu, A. Şengür, Dental Material Detection based on Faster Regional Convolutional Neural Networks and Shape Features, Neural Process Lett. 54 (2022) 2107–2126. <https://doi.org/10.1007/S11063-021-10721-5/FIGURES/15>.
- A. Imak, A. Celebi, K. Siddique, M. Turkoglu, A. Sengur, I. Salam, Dental Caries Detection Using Score-Based Multi-Input Deep Convolutional Neural Network, IEEE Access. 10 (2022) 18320–18329. <https://doi.org/10.1109/ACCESS.2022.3150358>.
- A. Imak, A. Çelebi, O. Polat, M. Türkoğlu, A. Şengür, ResMIBCU-Net: an encoder–decoder network with residual blocks, modified inverted residual block, and bi-directional ConvLSTM for impacted tooth segmentation in panoramic X-ray images, Oral Radiol. 1 (2023) 1–15. <https://doi.org/10.1007/S11282-023-00677-8/FIGURES/11>.
- A. Çelebi, A. Imak, H. Üzen, Ü. Budak, M. Türkoğlu, D. Hanbay, A. Şengür, Maxillary Sinus Detection on Cone Beam Computed Tomography Images using ResNet and Swin Transformer-based UNet, Oral Surg Oral Med Oral Pathol Oral Radiol. (2023). <https://doi.org/10.1016/J.OOOO.2023.06.001>.

1.2.3. Tezin Yenilikçi Yönü ve Ar-Ge Niteliği

Tez çalışmasında belirlenen diş hekimleri tarafından incelenmesi sonucunda, görüş birliği ile hastalık ve materyalleri içeren özgün bir veri seti oluşturulmuştur. Çalışma süresince, diş hastalık ve materyal tespiti için makine öğrenmesi ve derin öğrenmeye dayalı modeller geliştirilmiştir. Bu modellerin sınıflandırma performansları karşılaştırılmış ve son teknoloji yöntemlere kıyasla en iyi performansa sahip modeller elde edilmiştir. Türkiye Küçük ve Orta Ölçekli İşletmeleri Geliştirme Kurumu (KOSGEB) tarafından Ar-Ge ve Yenilikçiliği Destekleme Programı 62146 numaralı “Oral radyolojik görüntüleme tekniklerinde yapay zeka tabanlı uzman sistem tasarımı” projesi kapsamındaki bu çalışma kabul edilerek tamamlanmıştır.

1.2.4. Tezin Organizasyonu

Bu tez çalışması 8 ana bölümden oluşmaktadır. Sırasıyla birinci bölümde tez konusu ile ilgili genel bilgiler ve kapsamlı bir literatür incelemesi gerçekleştirilmiştir. Tezin amacı, çıktıları ve yenilikçi yönleri ortaya konularak, gerçekleştirilen çalışmaların literatüre yapılan katkıları belirtilmiştir. Son olarak tezin organizasyonu da bu bölümde sunulmuştur.

Bölüm 2’de teorik alt yapı başlığı altında okuyucuya tezin temel konusu diş anatomisi, anlatılarak detaylar verilmiştir.

Bölüm 3’de materyal ve metot kapsamında; tez çalışmasında kullanılan temel adımlarda derin öğrenme, önerilen modellerde kullanılan yöntemlerin teorik altyapısı, sınıflandırıcı yöntemleri ve performans metrikleri detaylı bir şekilde açıklanmıştır.

Bölüm 4’de, diş materyallerinin tespiti için geliştirilen iki aşamadan oluşan derin öğrenme tabanlı bir sistem verilmiştir. Önerilen modelin temelleri yine bu bölümde detaylandırılmıştır. Önerilen bu algoritmalar ve hibrit sistem, oluşturulan özgün veri seti ile mevcut farklı algoritmalar ile (Bölüm 3’de detaylandırılmıştır) test edilmiştir. Bu bölümdeki çalışmanın değerlendirilmesi sonucunda bir adet Science Citation Index Expanded indeksli makale yayınlanmıştır [47].

Bölüm 5’de diş çürüğü tespiti için önerilen yöntem ile skor tabanlı sistem detayları sunulmuştur. Literatürde yapılan çalışmalar ile karşılaştırılmıştır. Elde edilen iyi başarımlar sonuçları ile bir adet Science Citation Index Expanded indeksli makale yayınlanmıştır [48].

Bölüm 6’te konik ışınli bilgisayarlı tomografi görüntüleri kullanarak etkili bir maksiller sinüs tespiti için önerilen yöntem ile en gelişmiş yöntemlerle karşılaştırılması ilgili deneysel senaryolar açıklanmıştır [49].

Bölüm 7’de gömülü diş tespiti için önerilen piksel tabanlı bir derin mimari detayları sunulmuştur. Gerçekleştirilen uygulama sonucunda elde edilen sonuçlar sunulmuştur. Literatürde mevcut yöntemler ile karşılaştırılarak çalışma sonuçları incelenmiştir. Elde edilen iyi başarımlar sonuçları ile bir adet Science Citation Index Expanded indeksli makale yayınlanmıştır [50].

Son olarak Bölüm 8’de önerilen yöntemler ile yapılan çalışmalardan çıkarılan sonuçlar açıklanmıştır. Bu tez çalışmasının özgün katkıları ve öneriler kısmında gelecekte yapılması hedeflenen çalışmalara yer verilmiştir.


Dentin, mine yapısından daha yumuşak ve hassas bir yapıya sahiptir. Elastik ve sıkıştırılabilir canlı bir doku olarak dişin büyük bir kütesini oluşturmaktadır. Dentin, bulunduğu alan bölümünde pulpa içerisindeki merkezi siniri ile bağlanan küçük tübüler yapıları içermektedir. Canlılığını sürdüren bir diş yaşam boyunca dentin oluşumu gerçekleşmektedir.

Pulpa dişin en önemli merkezini oluşturan bölümdür. İçerisinde bulundurduğu damarlar ve sinirler aracılığı ile hem dişin beslenmesini hem de sıcaklık hissiyatının algılanmasını sağlamaktadır.

2.1.1. Diş Röntgen Türleri

Diş hekiminin mevcut aktif hastalığın derecesine ve hangi oral yapıları görmesi gerektiğine bağlı olarak alınan röntgenlerin türleri bulunmaktadır. Elde edilen görüntü çeşitleri şu şekilde detaylandırılmaktadır;

Bitewing röntgen en yaygın röntgen gruplarından biri olarak bilinmektedir. Genellikle alt ve üst arka çene dişlerinin bütün kronları görünecek şekilde ve kök kısmının ise 1/3'lük bir kısmın görüntülenmesi sağlanan bir röntgen türüdür. Şekil 2.2'de bitewing (ısırtma tekniği) ile elde edilen bir diş röntgeni türü gösterilmiştir [3].



Şekil 2.2. Bitewing röntgen

Periapikal röntgen diş hekimlerine detaylı olarak incelemek istedikleri dişin taçtan kökün sonuna kadar tamamının net bir şekilde analiz edilmesini sağlayan önemli bir görüntüleme türüdür. Periapikal, standart bitewing röntgende bulunamayan ağız sağlığı durumlarının teşhisinin çok önemli bir parçasıdır. Gömülü dişler, kistler, apseler ve hatta tümörler dâhil olmak üzere bir dizi farklı ağız sağlığı sorununu bulmakta yardımcı olabilirler. Şekil 2.3'te periapikal röntgen türü ile elde edilen bir diş röntgeni türü gösterilmiştir [3].



Şekil 2.3. Periapikal röntgen

Occlusal röntgen çoğunlukla çocuklarda diş gelişimi ve yerleşimini gözlemlemek için kullanılan bir görüntüleme türüdür. Üst veya alt çenede yerleşen neredeyse bütün dişlerin tamamını gösterir. Bu görüntü sayesinde ağız tabanı veya damak ile anatomik anormallikleri de tespit edebilmektedir. Şekil 2.4'te occlusal röntgen türü ile elde edilen bir diş röntgeni türü gösterilmiştir [3].



Şekil 2.4. Occlusal röntgen [3]

Panoramik röntgende makine kafanın etrafında döner ve hastanın tüm ağzının resmini tek bir görüntüde yakalayan iki boyutlu bir röntgendir. Bu tip görüntüleme tekniği; kistler, kırıklar, tümörler, etkilenen dişler ve diş çürüğü vb. gibi dişlerde bulunan farklı enfeksiyonları veya sorunları tespit etmek için kullanılmaktadır. Şekil 2.5'te panoramik röntgen türü ile elde edilen bir diş röntgeni türü gösterilmiştir [3].



Şekil 2.5. Panoramik röntgen

2.1.2. Diş Çürüğü

Ağız ve diş sağlığı sorunu olarak diş çürümesi insanlarda en yaygın görülen sorunlardan bir tanesidir. Diş çürümesi bazı bakterilerin ağız içerisinde gıda parçacıklarının fermente edilmesi


sonucu ortaya çıkan asidin dişin sert yapısında oluşan yıkım olarak tanımlanmaktadır. Erken tedavi ile kontrol altına alınmadığı durumlarda lezyonun boyutlarının ilerleyici bir durum oluşturması sonucu ağrı ve pulpa bölgesinin canlılığını yok etmeye kadar bir süreci içermektedir [51]. Şekil 2.6’da diş röntgeninde çürük bir örneği gösterilmiştir.



Şekil 2.6. Diş röntgen görüntüsünde diş çürüğü

2.1.3. Apse ve Kist

Diş absesi, diş çürümesinin sonucu oluşan bir durum olarak karşımıza çıkmaktadır. Dişin kırılması veya oyulması sonucunda da oluşabilmektedir. Diş minesindeki açıklıklar, bakterilerin dişin merkezine (pulpa) bulaşmasına izin verir. Oluşan enfeksiyon dişin kök kısmına ve dişin desteklemesini sağlayan kemiklere yayılabilmektedir [52]. Oluşabilecek bir apse durumu Şekil 2.7’de gösterilmiştir.




Şekil 2.7. Diş bölgesinde apse oluşumu

Enfeksiyon, iltihap toplanması ve diş içindeki dokuların şişmesi ile sonuçlanmaktadır. Bu durum şiddetli bir diş ağrısına neden olmaktadır. Apseyi temsil eden diş radyografisi Şekil 2.8’de gösterilmektedir.



Şekil 2.8. Apse gerçekleşmiş diş röntgeni görüntüsü

Diş özündeki enfeksiyon doğrultusunda oluşan Periapikal kist en sık görülen vakaların bir tanesidir. Radiküler kist olarakta bilinen bu kist çeşidi genellikle diş çürümesi veya travma sonucu pulpa bölgesindeki doku ölmesinden kaynaklanmaktadır. Genellikle periapikal kist asemptomatiktir (hastalıkla ilgili belirtiler göstermeme ve ağrı oluşmama durumu) fakat sinire baskı yaparlarsa ağrı veya hissizliğe sebep olabilmektedir. Bu diş hastalığı röntgende diş kökünün ucunun koyu siyah olarak görülmektedir [53]. Kisti temsil eden diş röntgeni Şekil 2.9 (a)'da ve kistten etkilenen hasta Şekil 2.9 (b)'de gösterilmiştir.




Şekil 2.9. Diş röntgeninde tespit edilmiş (a) kist röntgeni, (b) müzdarip hasta

2.1.4. Gömülü Diş

Gömülü dişler genetik, sistemik ve lokal gibi çeşitli etiyolojik faktörlere bağlı olarak gelişen patolojik bir durumdur. Dişin doğal sürme zamanları geldiği halde çene kemiği içinde kalıp normal konumunu alamamasıdır. Gömülü diş tanısında uzmanlar genellikle periapikal veya panoramik radyografileri kullanmaktadır. Ayrıca bu patolojik durum ileride perikoronit, neoplazmalar, orofasiyal ağrı, periodontitis, patolojik kırıklar, TME bozuklukları ve kistler gibi diş enfeksiyonlarına neden olabilir. Bu durumun diş problemlerinde görülme sıklığı %0.8 ile %3.6

arasında değişmektedir [36]. Şekil 2.10'da oluşabilecek bir gömülü diş durumu, panoramik radyografi üzerinde gösterilmiştir.



Şekil 2.10. Gömülü diş röntgeni görüntüsü

2.1.5. Maksiller Sinüs

Maksiller sinüs diş kökleri ile ilişkilidir. Bu nedenle dişlerdeki herhangi bir enfeksiyondan etkilenebilir veya aksine maksiller sinüs enfeksiyonu dişleri veya ağız dokularını etkileyebilir. Maksiller sinüs sıklıkla kendisi ile örtüşen maksiller azı dişlerinin apikal veya periodontal lezyonlara neden olmaktadır [31,54]. Tıp uzmanlarının en uygun tedavi seçeneklerini belirlemek için maksiller sinüs sınırlarını doğru bir şekilde bilmeleri ve dişlerle ilgili durumu radyografilerde netleştirmeleri gerekir. Sinüsün dişleri etkilemeyeceği düşünülse de maksiller sinüs dental tedavi endikasyonlarında öne çıkan bir faktördür. Şekil 2.11'de maksiller sinüs bölgesi gösterilmiştir.



Şekil 2.11. Maksiller sinüs


Diş hastanelerini ziyaret eden hastalar genellikle ilk konsültasyonda panoramik radyografi çekerler. Panoramik röntgenler ana şikayetle ilgili bulgular sağlayabilir ve tesadüfi bulguları saptayabilir. Bununla birlikte, radyopak yapılar (örn. damak tabanı, burun boşluğu tabanı ve alt konka) maksiller sinüslerle örtüşür; bu nedenle deneyimsiz diş hekimlerinin maksiller sinüs lezyonlarını teşhis etmesi zor olabilir ve klinikte önemli bulgular yoğun diş hekimleri tarafından gözden kaçabilmektedir [29,31].

2.1.6. Diş Materyalleri

Dişte dolgu, dişte oluşan çürükleri veya hasarları onarmak için kullanılan malzemelerdir. Çürükler, dişlerin sert dokularında önemli bozukluklara neden olabilir. Eksikliklere yönelik diş dolgusu, estetik etkilerinin yanı sıra dişlerin tam formunu ve çiğneme fonksiyonunu korumak için etkili bir yöntemdir. Dolgu materyali, diş kusurlarını doldurmak için kullanılan yapay bir restoratif materyaldir [55,56].

Dişte kaplama, çürük veya travma nedeniyle kırık veya aşırı madde kaybı olan dişlerin veya kanal tedavili dişlerin küçültülmesi ve kaplanması işlemidir. Kaplama, altındaki hasarlı dişe tam uyum sağlayarak dişi her yönden kaplayan diş restorasyonudur [55].

Dişte köprü, çürük veya kaybolan dişlerin yerine geçmek için kullanılan bir protezdir. Kısaca sabit protezler, doğal dişin bozulan şeklini düzeltmek veya eksik dişlerin yerine koymak amacıyla doğal dişler üzerinden destek alınarak yapılan protetik diş tedavi yöntemleridir [55]. Şekil 2.12’de köprü, kaplama ve dolgu materyallerini içeren örnek bir panoramik diş röntgen görüntüsü verilmiştir.



Şekil 2.12. Diş materyalleri

3. MATERYAL VE METOT


3.1. Derin Öğrenme

Derin öğrenme (deep learning), bir makine öğrenimi alt dalıdır ve çok katmanlı (derin) yapay sinir ağlarının eğitilmesini içerir. Yapı açısından bakıldığında, sinir ağları temel olarak girdi, gizli ve çıktı katmanları olmak üzere üç katmana ayrılır. Bu sinir ağları, insan beynine dayanmaktadır ve özellikleri öğrenmek, tecrübe kazanmak için otomatik olarak tasarlanmıştır. Bunlar görüntü sınıflandırması, konuşma tanıma, doğal dil işleme ve nesne algılama gibi çeşitli görevler için kullanılabilir. Derin öğrenme modeli büyük veri setleri ve güçlü bilgisayar kaynakları (GPU) gibi kullanılarak eğitilir. Bu modeller veri içindeki karmaşık desenleri ve ilişkileri öğrenir ve bu yüzden geleneksel makine öğrenimi algoritmaları için zor olan görevleri yapmak için uygundur. Öznitelik çıkarma aşaması bir görüntünün tanımlanması için gerekli görülen en temel adımlardan birisidir. Geleneksel makine öğrenimi algoritmaları, ham verilerden elde edilen manuel olarak oluşturulmuş özellikleri veya diğer tekniklerden çıkarılan özellikleri kullanarak belirli işlemleri yürütmek üzere eğitilir. Derin öğrenme mimarisi ise uzman bilgisi veya manuel olarak spesifik belirlenen öznitelik çıkarma yöntemine gerek olmadan, otomatik olarak öznitelikleri kendisi elde etmektedir. Ayrıca eğitim aşamasındaki öğrenme süreci uzun zaman almasının yanında test sürecinde sınıflandırma aşaması, geleneksel Yapay Sinir Ağları (YSA)'na göre hızlıdır [57].

Derin öğrenme algoritmasında performans büyük ölçüde veri setinin kalitesine ve boyutu ile bağlantılıdır. Derin ağlardaki milyonlarca parametrenin güncellenmesi için büyük veri setlerine ihtiyaç duymaktadır. Ayrıca eğitim sürecinin zaman almasından kaynaklı, sürenin azaltılması için hesaplama gücü yüksek donanımlar ile bu problem ortadan kaldırılabilmektedir. Üretilen güçlü GIÜ (Grafiksel İşleme Ünitesi) kartları sayesinde bu tür sorunlar çözülmeye başlanmıştır [58].

Derin öğrenme, 2000'li yılların başından beri aktif olarak araştırılan bir konudur. 2006'dan önce, hesaplama karmaşıklığıyla ilgili endişeler nedeniyle derin öğrenme algoritmaları yaygın olarak kullanılmıyordu. Hinton ve arkadaşları derin güvenli ağların (Deep Belief Networks) çalışma prensiplerini ve bu ağların eğitilmesine yönelik bir algoritmayı tanımladı [59]. Salakhutdinov ve Larochelle derin boltzmann makinelerinin (DBMs) nasıl çalıştığını ve bu makinelerin eğitilmesine yönelik bir algoritmayı tanımladı [60]. 2012 yılında düzenlenen Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet, Competition 2012), nesne tanımlama alanında en büyük yarışmalardan birisidir. Krizhevsky ve Sutskever Evrimsel Sinir Ağı (ESA) mimarisi ile bu yarışmayı kazanarak, derin öğrenme bilim dünyasında büyük etki oluşturmuştur [61]. Bu, yeni modeller ve mimariler dahil olmak üzere alanda önemli ilerlemelerin yanı sıra çok çeşitli görevlerde geliştirilmiş iyi performanslara yol açtı. Alandaki yayınların sayısı önemli ölçüde arttı ve bu da bilim camiasında derin öğrenmeye artan ilgiyi ve önemi göstermektedir. 2001 yılından


2022 yılına kadar yılda "Deep Learning" kelimesiyle ilgili yapılan yayınların sayısı Şekil 3.1’de gösterilmiştir. Bu veriler ScienceDirect veri tabanından elde edilmiştir ve veri tabanında yapılan arama sadece “Deep Learning” anahtar kelimesiyle sınırlandırılmıştır.



Şekil 3.1. ScienceDirect veritabanında “Deep Learning” anahtar kelimesini içeren yayın sayısı

Makine öğrenimi algoritmalarının gelişmesiyle birlikte yüksek kapasiteli sistemlere olan talepte artmıştır. Bu talep, büyük verilerin verimli bir şekilde işlenmesi için yüksek performanslı CPU’ların ve GPU’ların kullanımı da dahil olmak üzere hem donanım hem de yazılımda yeni teknolojilerin geliştirilmesine yol açtı. Son on yılda, hesaplama hızı önemli ölçüde arttı ve bazı tahminler 1000 kat artış olduğunu gösteriyor. Makine öğrenimi için donanım yeteneklerindeki ve büyük miktarda verinin kullanılabilirliğindeki gelişmelerden dolayı alanın büyümesini daha da hızlandırdı [62].

Derin öğrenme, içerdiği evrişim katmanları, havuzlama katmanları ve doğrusal olmayan bağlantılar sayesinde çok sayıda görevde en ileri teknik sonuçları elde etmiştir. Ayrıca bilgisayar görüşü, doğal dil işleme, konuşma tanıma gibi birçok problemi çözmek için popüler bir yöntem haline gelmiştir [63–66]. ESA mimarilerinin genel yapısı Şekil 3.2’de gösterilmiştir.



Şekil 3.2. ESA mimarilerinin genel yapısı [67]

ESA mimarisi, görüntülerdeki kenar, renk ve doku gibi özellikleri kullanarak nesne algılama ve sınıflandırma görevlerini gerçekleştiren bir derin öğrenme mimarisidir. Şekil 3.2’de gösterildiği gibi, ESA mimarisi öncelikle görüntüdeki öznitelikleri elde etmek için birkaç evrişim katmanı kullanır. Bu evrişim katmanları, görüntü üzerinde dikey, yatay veya farklı rotasyonlarda filtreler kullanarak kenar, renk ve doku bilgilerini elde eder. ESA mimarisi, geleneksel olarak kullanılan yöntemlerde olduğu gibi Gabor, Sobel, Prewitt gibi filtrelerin yanı sıra, kendi özelleştirilmiş filtreleri de kullanabilir. Bu filtreler, her bir evrişim katmanında farklı ağırlıklara sahiptir ve her katmanın çıkışında farklı öznitelikler hesaplanır. Ayrıca, daha derin katmanlar daha yüksek seviyeli özniteliklerin çıkarılmasına izin verir [68].

3.1.1. Evrişimsel Sinir Ağlarının Bileşenleri

ESA mimarisi, temel olarak girdi, gizli ve çıktı katmanları olmak üzere üç katmana ayrılır. Ayrıca gizli katman, evrişimli katman, havuzlama katmanı ve tam bağlantılı katmandan oluşmaktadır. Bu katman yapıları aşağıda başlıklar halinde detaylandırılmıştır.

3.1.1.1. Girdi Katmanı

Evrişimli Sinir Ağındaki (ESA) giriş katmanı, ham girdi verilerinin ağı beslediği ilk katmandır. Girdi katmanının herhangi bir öğrenilebilir parametresi yoktur ve rolü bir sonraki katmanın işlemesi için veri sağlamaktır. Giriş katmanının şekli, ESA’nın işlemek üzere tasarlandığı veri türüne bağlıdır. Örneğin, görüntü sınıflandırma görevlerinde, giriş katmanı bir şekle (yükseklik, genişlik, derinlik) sahip olabilir; burada yükseklik ve genişlik görüntünün boyutlarıdır ve derinlik, renk kanallarının sayısıdır (örn. RGB). Giriş katmanı, sonraki katmanlardaki özellik


haritalarının boyutunu da belirler. Ağ tarafından verimli bir şekilde işlenmesini sağlamak için girdi verilerinin boyutuyla eşleşen uygun boyutta bir girdi katmanına sahip olmak çok önemlidir [57].

3.1.1.2. Evrişim Katmanı

Evrişim işlemi ESA mimarisinin temelini oluşturmaktadır. Bu dönüşüm işlemi aslında görüntü işleme gibi pek çok işlemde kullandığımız basit bir filtreleme işlemidir. Bu katmandaki $n \times n$ boyutlu filtreler tüm imge boyunca gezdirilmesi ile çıkış verisi oluşturulur. Bu evrişim işlemi sonucunda oluşan çıkış verisine özellik haritası adı verilmektedir. Girdi görüntülerinden filtreleme yapılarak elde edilen üst düzey öznitelikler, evrişim ve havuzlama katmanı tarafından gerçekleştirilir. Girdi olarak iki boyutlu bir görüntü kullanırsak, iki boyutlu bir çekirdek kullanılır. Evrişim, Denklem 3.1’de gösterilen parametreler kullanılarak temsil edilir.

$$X_j^l = f\left(\sum_{i \in M_j} X_i^{l-1} \cdot k_{ij}^l + b_j^l\right) \quad (3.1)$$

Burada, önceki katmanların özellik haritası x_i^{l-1} ifadesi ile temsil edilir. M_j , k_{ij}^l ve b_j^l , sırasıyla girdi haritası seçimini, evrişim çekirdeğini ve eğitilebilir ek bias terimlerini temsil eder. Evrişim işlemi bir $f(\cdot)$ aktivasyon fonksiyonundan geçirilir [69]. Görüntüye uygulanan her bir filtreye özgü oluşan aktivasyon haritası ile yeni özellikler keşfedilmektedir. Şekil 3.3’te verilen giriş görüntüsü 5×5 ’lik bir matris olduğu düşünülürse, 3×3 ’lük bir filtre ile evrişim işlemi gerçekleştirilmiştir.



Şekil 3.3. Evrişim işlemi ile ilgili örnek bir uygulama

Evrişim işlemi filtrenin giriş görüntüsü üzerine oturtularak belirlen bir adım (stride) ile sağa-sola ve aşağı-yukarı kaydırma işlemidir [20]. Kaydırma işlemi sırasında, filtre ile imge

üzerindeki piksel değerleri noktasal olarak çarpılarak hesaplama gerçekleştirilir. Elde edilen bu değerler toplanarak net sonuç bulunmaktadır. Bu işlem imge üzerinde kaydırılarak her bir işlem için sonuç bulunarak yeni bir imge elde edilmiş olur. Belirlenen her bir filtre aslında YSA'ya ait bir nöronu temsil etmektedir. Bu nöronun ağırlıkları ise filtreye özgü belirlenmiş içerisindeki değerlerdir [24]. W_i genişliği, H_i yüksekliği ve C kanalı olan ($W_i \times H_i \times C$) bir girdi görüntü için filtreleme sonucunda Denklem 3.2'de gösterilen yeni boyutlar elde edilir.

$$\begin{aligned} W_{\zeta} &= \frac{W_i - cb + 2p}{s} + 1 \\ H_{\zeta} &= \frac{H_i - cb + 2p}{s} + 1 \\ Y_{\zeta} &= W_{\zeta} \times H_{\zeta} \times cs \end{aligned} \quad (3.2)$$

Burada;

W_{ζ} ve H_{ζ} : Sırasıyla çıktının genişlik ve yükseklik değerlerini,

Y_{ζ} : Elde edilen yeni çıkış boyutu

s : Görüntünün üzerinde hareket ettirilen adım sayısı,


Dolgulama (P): Girdinin dış bölgelerine öğeler ekleyerek girdi boyutunu genişletme işlemi,

cb : Filtre boyutu,

cs : Evrişim işleminde kullanılan filtre sayısını ifade etmektedir.

3.1.1.3. Havuzlama Katmanı


Bu katman derin öğrenme mimarisinde evrişim işlemi sonucunda oluşan görüntü boyutunu azaltmak için kullanılmaktadır. Görüntünün alt örnekleme işlemini yaparak bir sonraki ağ katmanları için daha az hesaplama yükü oluşturma ile birlikte modelin ezberlemesini önleme gibi avantajlar sağlamaktadır. İlk adımda gerçekleştirilen evrişim işlemine benzer olarak havuzlama katmanında da belirli filtreler tanımlanmaktadır. Maksimum, minimum veya ortalama gibi alınması istenilen değerler için oluşturulmuş filtreler görüntünün tüm pikselleri üzerinde belirlenen adım oranında kaydırılarak elde edilir [70]. Havuzlama katmanı genellikle bir veya daha fazla evrişimli katmandan sonra kullanılır ve görüntülerin ve diğer veri türlerinin hiyerarşik temsillerini öğrenmelerini sağlayan ESA'ların önemli bir yönüdür. Şekil 3.4'te, 4×4 boyutundaki bir görüntü üzerinde 2×2 pencere boyutunda maksimum, minimum ve ortalama havuzlama işlemlerinin nasıl uygulandığına dair bir örnek sunulmuştur.



Şekil 3.4. Havuzlama işlemi için örnek bir gösterim

3.1.1.4. Yukarı Örneklemeye Katmanı

Yukarı örneklemeye katmanı, girdinin boyutunu artırmak için kullanılan bir katman türüdür. Havuzlama işlemi gibi, boyut azaltma işlemi yapmak yerine boyut artırma işlemi yapar. Yukarı örneklemeye katmanı, U-Net mimarisi gibi anlamsal bölütleme görevleri için önemli bir derin öğrenme modelinin bir parçasıdır. U-Net mimarisi, ağırlık kodlayıcı kısmının bir dizi evrişimli ve havuzlama katmanını kullanarak girdiden özellikleri çıkardığı ve ağırlık kod çözücü kısmının mekânsal bilgileri kurtarmak için yukarı örneklemeye katmanlarını kullandığı bir kodlayıcı-kod çözücü yapısına sahiptir [71,72]. Şekil 3.5'te, yukarı örneklemeye katmanının nasıl uygulandığına dair bir örnek gösterilmektedir.







Şekil 3.5. Yukarı örneklemeye işlemi için örnek bir gösterim

3.1.1.5. Aktivasyon Fonksiyonu

Ağın girdi verilerinden çıkarım yapmasını ve nöronların aktivasyon seviyelerini belirlemek için kullanılır. Bu sayede, ağın doğrusal olmayan veri kümelerini daha etkin bir şekilde işlemesi sağlanır. Temel olarak yapay sinir ağlarının yapısında girdiler belirli bir ağırlık ile çarpılıp bias eklenmesi sonucu bir değer elde edilmektedir. Son olarak elde edilen bu değer aktivasyon fonksiyonundan geçirilmesi sonucu nihai çıkış veya bir başka nöronun girişi olabilmektedir.

Aktivasyon fonksiyonu kullanılmayan bir sinir ağıının çıkışı doğrusal olarak kalması mümkün olacağından, sınırlı öğrenme gücüne sahip lineer regresyon gibi yaklaşacaktır. Tablo 3.1’de popüler olarak kullanılan aktivasyon fonksiyonları verilmiştir.

Tablo 3.1. Popüler olarak kullanılan aktivasyon fonksiyonları

Aktivasyon Fonksiyonu	Denklemleri	Grafiği
Sigmoid	$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$	
Tanh	$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
ReLU	$\text{ReLU}(x) = \max(0, x)$	
Leaky ReLU	$\text{L_ReLU}(x) = \begin{cases} xa, & x < 0 \\ x, & x \geq 0 \end{cases}$	

Derin öğrenme ile yapılan literatürdeki birçok çalışmada Doğrultulmuş Lineer Birim (rectified linear unit- ReLU) aktivasyon fonksiyonu çoğunlukla kullanılmaktadır. ReLU fonksiyonu, girdilerin pozitif olması durumunda aktivasyon seviyelerini sıfırdan büyük tutar ve negatif girdileri sıfıra eşitler. Hesaplanması, diğer aktivasyon fonksiyonlarından daha hızlıdır ve bu modelin eğitimi sırasında daha hızlı işleme sağlar [71–73].


3.1.1.6. Tam Bağlı Katman

Tam bağlı katman, derin öğrenme modellerinde son katman olarak kullanılır ve kendinden önce gelen katmanın tüm nöronlarına bağlıdır. Bu katman, $1 \times N$ boyutlu bir matristen oluşmaktadır. Her nöron, birbirinden farklı ağırlıklardan geçirilen girdi özelliklerini birleştirir. Tam bağlı katman genellikle sınıflandırma görevlerinde modelin sınıf skorlarını optimize etmek için kullanılır.

Bağlantıları sayesinde, bu katman, önceki katmandaki özelliklerin veya nöronların öğrendiği temel özelliklerin özelleştirilmesine ve daha fazla sınıflandırma performansına yardımcı olur [58].

3.1.1.7. Dropout Katmanı

Çok derin katmanlı ağ mimarilerinde aşırı öğrenme durumunun oluşması mümkün olabilmektedir. Dropout, derin öğrenme modellerinde aşırı öğrenme (overfitting) problemini çözmek için kullanılan bir yöntemdir. Bu yöntem, eğitim sırasında rastgele seçilen bir grup nöronun (“dropout rate” olarak adlandırılır) işlevsiz hale getirilmesi yoluyla gerçekleştirilir. Bu sayede, modelin farklı özellikleri belirleyen nöronların bağımlılığı azaltılır ve modelin daha geniş bir yelpazede özellikler öğrenmesi sağlanır. Ancak, dropout kullanırken dropout oranı ve nöronların hangilerinin bırakılacağı gibi parametrelerin doğru bir şekilde ayarlanması önemlidir. Bu sayede modelin performansı optimize edilir [70]. Şekil 3.6’da dropout uygulanmış bir ağ örneği gösterilmiştir.



Şekil 3.6. Dropout uygulanmış ağ örneği

3.1.1.8. Normalizasyon

Normalizasyon katmanı, evrişim katmanından elde edilen verileri belirli bir düzen içerisinde standartlaştırmak ve bu sayede eğitim sürecini daha verimli hale getirmek için kullanılan bir tekniktir. Normalleştirmenin amacı, modelin aşırı uyumunu önlemek ve girdi değerlerinin tutarlı bir aralıkta olmasını sağlayarak eğitimi hızlandırmaktır. Özellikle yüksek boyutlu ve farklı ölçeklerde verilerle çalışıldığında modelin performansını arttırabilmektedir [70]. Eğitim sürecini hızlandırmak için bu tez çalışmasında batch normalizasyon kullanılmıştır. Eğitim sırasında bir sinir ağındaki katmanlar, kendinden önceki katmanların değer dağılımlarından etkilenmektedir. Bu değişkenlikler eğitim hızının azalmasına neden olmaktadır. Batch normalizasyon (BN) her katmanda girdi dağılımlarını standartlaştırarak eğitimin hızlandırılmasını sağlar. Normalizasyon

her katmandaki dağılımların değişimleri ortalamayı 0'a ve varyansı 1'e ayarlayarak kontrol etmektedir [74]. Batch normalizasyon Denklem 3.3'te verilmiştir;

$$BN(X) = \gamma \frac{X - E[X]}{\sqrt{V[X] + \epsilon}} + \beta \quad (3.3)$$

Burada, X batch normalizasyonun katmanına girişi, V(.) varyansı, E(.) ortalamayı ve ϵ ise sayısal kararsızlığı önlemek için eklenmekte olan sabiti ifade etmektedir. Denklemden ayrıca γ ve β olmak üzere iki öğrenilebilir parametreden oluşmaktadır [75].


3.1.1.8. Sınıflandırma Katmanı

ESA mimarisine dayalı olan modellerde, sınıflandırma katmanı, tam bağlı katmandan gelen sayısal değerlerin son işlemi olduğu için modelin sınıflandırma yapabilmesi için oldukça önemlidir. Bu katman, genellikle softmax çoklu sınıflandırıcı kullanarak çıkış değerlerini her sınıf için 0-1 aralığında olacak şekilde normalize eder. Yani, bu katman, modele özgü her sınıf için bir olasılık dağılımı üretir. Sonuçlar daha sonra, tahmin edilen sınıf etiketini belirlemek için karşılaştırılır ve en yüksek olasılıksal değere sahip sınıf etiketi seçilir [58].

3.1.2. AlexNet

AlexNet, 2012 yılında yayınlanan bir makale ile derin öğrenmenin tekrar popüler hale gelmesini sağlayan ilk çalışmalardan biridir [61]. AlexNet, daha önceki mimarilerin aksine, birbirini takip eden beş adet evrişim katmanı, yedi adet ReLU aktivasyon fonksiyonu katmanı, üç adet havuzlama katmanı (maksimum), üç adet tam bağlı katman, iki adet normalizasyon katmanı, iki adet dropout katmanı ve son olarak softmax sınıflandırıcı katmanına sahip olduğu için daha derin bir ağıdır. AlexNet, evrişim ve havuzlama katmanlarından oluşan bir önceki mimari olan LeNet mimarisine çok benzemektedir. Ancak AlexNet, LeNet'ten daha fazla katman ve parametre içermektedir. AlexNet'teki evrişim katmanları, önceki katmanın her bir özelliğine filtre uygulayarak, bir sonraki katmana özellik haritası çıkarmaktadır. Havuzlama katmanları, özellik haritalarının boyutunu azaltarak ve hesaplama yükünü azaltarak, bilgi kaybını en aza indirmektedir. AlexNet'teki ReLU aktivasyon fonksiyonları, özellik haritalarındaki negatif pikselleri 0 ile değiştirerek, hesaplama verimliliğini arttırmaktadır. Ayrıca normalizasyon katmanları, özellik haritalarının normalleştirilmesine yardımcı olmaktadır. Dropout katmanları, aşırı uyum sorununu önlemek için rastgele olarak bazı nöronları kapatmaktadır. Son olarak, softmax sınıflandırıcı katmanı, özellik haritalarının sınıflandırma işlemine tabi tutulmasını sağlamaktadır. AlexNet, ImageNet veri kümesindeki 1,2 milyon resim ve 1000 farklı nesne sınıfı üzerinde eğitilmiştir. Bu eğitim, 6 gün süren bir süreçte gerçekleştirilmiştir. Eğitim sonucunda, AlexNet, o döneme kadar elde edilen en düşük hata oranlarından birini elde etmiştir ve büyük bir

sıçrama yaratmıştır. AlexNet, derin öğrenme alanında bir dönüm noktası olarak kabul edilmektedir ve günümüzde bile sık sık referans alınan bir mimari olarak kullanılmaktadır [76]. Bu mimarinin çalışma prensibi Şekil 3.7’de gösterilmiştir



Şekil 3.7. AlexNet mimarisi

3.1.3. MobileNetV2

MobileNetV2’nin temel yapısı derinlemesine ayrılabilir evrişimler kullanan hafif, düşük güç tüketimli ve yüksek performanslı bir CNN mimarisidir [77]. Genel olarak MobileNetV2’nin iç yapısı 3 katmandan oluşmaktadır. İlk katman; 1×1 evrişim, BN ve ReLU aktivasyon fonksiyonundan oluşmaktadır. İkinci katman; derinlemesine ayrılabilir evrişim, BN ve ReLU aktivasyon fonksiyonuna sahiptir. Son aşamada ise 1×1 ’lik bir evrişim ve BN katmanı ile tamamlanmaktadır. Derinlemesine evrişim, geleneksel evrişim işlemini derinlik yönünden evrişim (Dconv) ve 1×1 ’lik noktasal yönden evrişim (Pconv) olarak iki ayrı katmandan oluşmaktadır. Girdi haritalarının tüm kanallarına tek bir filtre uygulamak için derinlemesine evrişim kullanır. Dconv Denklem 3.4’te verildiği gibi tanımlanabilir;

$$Dconv(y, x, j) = \sum_{m=1}^k \sum_{n=1}^k K(m, n, j) * I(y + m - 1, x + n - 1, j) \quad (3.4)$$

Burada, K , $k \times k$ boyutunda, c_{in} derinliğinde evrişim çekirdeklerini ifade eder. c_{in} giriş kanallarının sayısını ve c_{out} sonuç kanallarının sayısıdır. K ’daki c_{in}^{th} filtre, I giriş özellik haritasının c_{in}^{th} kanalına uygulanır. Sonuç olarak Dconv’nin c_{out}^{th} kanalı üretilmektedir. Elde edilen bu kanal çıktılarına noktasal evrişim adı verilen 1×1 ’lik bir evrişim işlemi uygulanmaktadır. Pconv Denklem 3.5’te verildiği gibi tanımlanabilir;


$$Pconv(y, x, l) = \sum_{j=1}^{c_{in}} Dconv(y, x, j) * P(j, l) \quad (3.5)$$

1×1 boyutlu noktasal evrişim çekirdeğinin çıktısı $1 \times 1 \times c_{in} \times c_{out}$ olmaktadır [6]. Derinlemesine ayrılabilir evrişimlerin (Cds) ve standart evrişimlerin (Cs) hesaplamaları sırasıyla Denklem 3.6 ve Denklem 3.7’de verildiği gibi hesaplanabilir;

$$Cds = k \times k \times h_i \times w_i \times c_{in} + h_i \times w_i \times c_{in} \times c_{out} \quad (3.6)$$

$$C_s = k \times k \times h_i \times w_i \times c_{in} \times c_{out} \quad (3.7)$$

Burada h_i ve w_i sırasıyla giriş özellik haritasının yüksekliği ve genişliğini ifade etmektedir. Denklem 3.6 ve Denklem 3.7 bir birbirine oranlanırsa yaklaşık olarak $1/k^2$ 'lik bir sonuç çıkmaktadır. Bu sayede hesaplama maliyeti, standart evrişimlerin hesaplama maliyetine göre 8 ila 9 kat daha azalmaktadır [78]. Bu yapısı ile yürütme hızını ve bellek tüketimini optimize etmektedir. MobileNetV2 yapısı Şekil 3.8'de gösterilmektedir.



Şekil 3.8. MobileNetV2 genel yapısı

3.1.4. Transfer Öğrenme

ESA mimarilerinin eğitimi genellikle uzun sürebilir. Bunun nedeni, birçok parametrenin optimize edilmesi gerektiği için veri setleri üzerinde birçok eğitim tur sayısı (epoch) çalıştırılması gerektiğidir. Bu durum, özellikle büyük veri kümeleri ile çalışıldığında daha da belirgin hale gelmektedir. Geleneksel olarak, bir görev için yeterli veriye sahip olmak, makine öğrenmesinde başarı elde etmek için kritik öneme sahiptir. Aynı zamanda ESA mimarileri, eğitim sırasında yüz binlerce parametre öğrenir. Bu nedenle, gelişmiş bir ağ mimarisi, yeterli performansı elde etmek için geniş bir veri kümesi ile eğitilmelidir. Veri setinin sınırlı boyutu, ESA katmanları ile ayırt edici öznelikleri çıkarmak için yeterli olmamaktadır. Bu yüzden küçük bir veri kümesi kullanılarak sıfırdan eğitilmiş bir derin öğrenme modelinin yüksek performans elde etmesi oldukça zordur. Bu yüksek parametre sayısından kaynaklanan veri yetersizliği sorununu çözmek için transfer öğrenme olarak adlandırılan bir yaklaşım gerçekleştirilmiştir [66,79–81]. Transfer öğrenme, makine öğrenmesinde yaygın olarak kullanılan bir tekniktir ve öğrenme sürecinde farklı görevler arasında bilginin paylaşılmasını sağlar. Bir görev için önceden öğrenilmiş bilgiyi, benzer veya farklı bir

görev için kullanarak öğrenme sürecini hızlandırır ve daha iyi sonuçlar elde edilebilmektedir. Bu nedenle, transfer öğrenme, makine öğrenmesi alanında yaygın olarak kullanılan ve son derece faydalı bir tekniktir. Özellikle derin öğrenme yöntemlerinin yaygınlaşmasıyla birlikte, transfer öğrenme daha da önemli hale gelmiştir.

Transfer öğrenme yöntemi, genellikle bir milyondan fazla örnek içeren büyük veri kümeleri kullanılarak önceden eğitilmiş ağ mimarileri kullanmak yaygındır. Önerilen yeni ağ mimarisi, önceden eğitilmiş ağ mimarisinin belli bir bölümü olan omurga ağı olarak kullanılabilir. Yeni ağ mimarisi, önceden eğitilmiş omurga ağından bazı katmanlarla bağlantı kurarak veya bu omurga ağına yeni katmanlar ekleyerek geliştirilebilir. Bu şekilde, transfer öğrenme sayesinde yeni bir problem için daha az veri kullanılarak daha iyi sonuçlar elde edilebilir. Transfer öğrenme için kullanılan Tablo 3.2’de de belirtilen başlıca ağ modelleri arasında, özellikle görüntü işlemede kullanılan AlexNet, VGG, Inception ve ResNet gibi ağ mimarileri yer almaktadır. Bu ağ modelleri, özellikle ImageNet [61] gibi yüksek boyutlu veri kümeleriyle eğitilerek geniş bir özellik yelpazesi öğrenirler. Daha sonra, bu özellikler, önceden eğitilmiş ağ mimarilerinden alınarak başka bir görev için eğitilecek olan yeni bir ağ mimarisine aktarılır. Bu sayede, yeni ağ mimarisi, daha az veriyle daha hızlı bir şekilde eğitilebilir ve daha yüksek performans sergileyebilir. Omurga ağı seçimi, veri kümesi ve hedef görevin özellikleri göz önünde bulundurularak yapılmalıdır. Bu, transfer öğrenme yöntemini kullanarak hedef görev için en iyi performansı elde etmek için önemlidir [69,71,82].

Tablo 3.2. Transfer öğrenme için sıklıkla kullanılan ağ modelleri

Model	Katman Sayısı	Parametre Sayısı
AlexNet [61]	8	61M
Vgg16 [83]	16	138M
Vgg19 [83]	19	144M
SqueezeNet [84]	18	1.24M
GoogLeNet [85]	22	7M
Xception [86]	71	22.9M
DarkNet19 [87]	19	20.8M
MobileNetV2 [77]	53	3.5M
Inceptionv3 [88]	48	23.9M
ShuffleNet [89]	50	1.4M
ResNet18 [90]	18	11.7M
ResNet50 [90]	50	25.6M
ResNet101 [90]	101	44.6M

3.1.5. Özel Blok Yapıları

ESA mimarileri ile ilgili birçok çalışmada, katman sayısı artırılarak daha derin ve anlamsal öznetelikler elde etmek amaçlanmıştır. Ancak, ESA'nın çok sayıda katmana sahip olması, kaybolan gradyan problemine yol açmıştır. Kaybolan gradyan problemi, bir derin öğrenme modelinin eğitim sürecinde, gradyanların geriye doğru (backpropagation) yayılması sırasında kaybolması veya eksik kalması durumudur. Bu durum, daha önceki katmanlara ilerlerken gradyanların giderek küçülmesi veya sıfıra yaklaşması nedeniyle ortaya çıkar. Bu da daha derin katmanlara ulaşan gradyanların güncellenememesi ve öğrenilememesi anlamına gelir. Kaybolan gradyan problemi, ağıın eğitimi yavaşlatır veya durdurur ve modelin yeterince derin öğrenememesine neden olabilir [66,83,90,91].

3.1.5.1. Kaybolan Gradyan Problemi

ESA mimarileri, parametrelerin eğitimi için geriye doğru yayılım (backpropagation) modelini kullanır. Geri yayılım ağıın çıkışındaki hata ile ağırlıklar arasındaki ilişkiyi bulmaktadır. Bu işlem, Denklem 3.8'de verildiği gibi türev zincir kuralı kullanılarak gerçekleştirilir.

$$w_1 = w_1 - \alpha \frac{\partial j(w)}{\partial w_1} \quad 0 < \alpha < 1$$
$$\frac{\partial j}{\partial w_1} = \frac{\partial j}{\partial e} \frac{\partial e}{\partial w_{n-1}} \dots \frac{\partial w_2}{\partial w_1} \quad (3.8)$$


Burada j ve e sırasıyla amaç fonksiyonu ve hatayı göstermektedir. w_1 ağırlık parametresinin güncel değeri için $\frac{\partial j}{\partial w_1}$ türevi hesaplanmalıdır. Denklem 3.8'de görüleceği üzere $\frac{\partial j}{\partial w_1}$ in hesaplanmasında zincir kuralı uygulanmaktadır. α değeri, adım genişliğini belirler ve ağıın parametrelerinin ne kadar değiştirileceğini kontrol eder. Genellikle küçük bir değer seçilmesinin nedeni, parametrelerin çok büyük bir adımda güncellenmektedir [90].

VGG19 gibi çok katmanlı ağlarda, zincir kuralından dolayı $\frac{\partial j}{\partial w_1}$ küçülmekte ve sonunda sıfıra yaklaşmaktadır. Bu durum ilk katmanların eğitimi engelleyerek kaybolan gradyan problemine neden olmaktadır. ESA mimarilerinde bu sorunun üstesinden gelmek için ResNet ve Dense bloklar gibi ara bağlantı modeli geliştirilmiştir. Bu model, önceki katmanların çıktılarını, sonraki katmanlara birleştiren ek bağlantılar ekler [90–92].

3.1.6. ResNet Mimarisi

Derin evrişimli sinir ağları, bilgisayar görüşü ve diğer pek çok alanda önemli başarılar elde etmiştir. İlk olarak geliştirilen AlexNet [61] ve VGG [83] ağları ile birçok sorun için üstün performans elde edilmiştir. Ayrıca, katman derinliğini artırmak ve daha derin ve anlamsal özellikleri çıkarmak için geliştirmeler yapılmıştır. Ancak, ağıın katman derinliği arttıkça, gradyanların kaybolması problemi ortaya çıkmaktadır. Bu durum, daha fazla katman eklenmesiyle

elde edilen anlamsal özelliklerin sınıflandırma veya tespit başarısının azalmasına neden olmaktadır. Bu problemten yola çıkarak, He ve arkadaşları tarafından artık blok mimarisi geliştirilmiştir [90]. Temel olarak bu blok yapısı ağıın katman derinliğinin artırılmasıyla birlikte performansı arttırmak için artık bağlantılar kullanır. Şekil 3.9, He ve arkadaşları tarafından bu problemten yola çıkılarak geliştirilen artık blok yapısını göstermektedir.



Şekil 3.9. Artık blok

Artık Blok yapısı, belirli bir katman aralığında atlama bağlantıları içerir. Bu atlama bağlantıları, ilk katmandaki özellik haritalarının doğrudan son katmana ulaşmasını sağlar. Katmanların çıktısını bir sonraki katmana ekleyerek, daha derin ağlar oluşturmanın yolunu açar. Denklem 3.9, atlama bağlantılarının matematiksel ifadesini göstermektedir;


$$H(x) = f(x) + x \quad (3.9)$$

Burada, $f(\cdot)$ işlevi ara katmanları belirtir ve x , artık bloğun giriş özellik haritasıdır. Bu yaklaşım, ağıın öğrenmesini kolaylaştırır ve daha derin ağların da eğitilebilir olmasını sağlamaktadır.

Artık blok yapısı, AlexNet ve VGG gibi katmanlara kıyasla ResNet18, ResNet34, ResNet50 ve ResNet101 gibi çok daha derin ESA mimarilerinin tasarlanmasını sağlamıştır. ResNet, pek çok görsel tanıma ve nesne tespiti uygulamasında kullanılmıştır ve derin öğrenme alanında üstün performans sağlamıştır [90,93].

3.1.7. DenseNet Mimarisi

Huang ve arkadaşları tarafından geliştirilen DenseNet, ResNet mimarisine benzer özelliklere sahiptir [92]. Ancak ResNet'te, her bir modül önceki modülden bilgi alırken, DenseNet'te, modüller kendisinden önceki her bir modülden bilgi alarak ileri beslemeli yoğun bir şekilde birleşim gerçekleştirirler. Bu nedenle, DenseNet mimarisi, ResNet'ten daha yoğun ve daha çeşitli özellikler elde edebilir. Şekil 3.10'da, normal ESA modeli, ResNet modeli ve DenseNet modeline ait temsili birer akış diyagramı gösterilmiştir. Normal ESA modeli, geleneksel mimarilerinde kullanılan basit bir yapıya sahiptir. ResNet mimarisi, bloklu bir yapıda olup her blok kendisinden önceki bloklardan bilgi almaktadır. DenseNet mimarisi ise her bloğun kendisi ile önceki tüm bloklardan bilgi aldığı bir yapıdadır [58,94–97].



Şekil 3.10. (a) ESA mimarisi, (b) ResNet mimarisi, (c) DenseNet mimarisi [58]

3.1.8. Çift Yönlü Evrişimsel Uzun Kısa Süreli Bellek

Uzun Kısa Süreli Bellek (LSTM), sıralı verilerdeki uzun vadeli bağımlılıkları öğrenmek için gradyan kaybolması ve gradyan patlaması problemini çözmek için geliştirilmiş bir tekrarlayan sinir ağı modelidir [98]. Bu sorun giriş verileri dizisi boyunca alakasız bilgileri ortadan kaldırırken, çeşitli kontrol kapıları ile gizli duruma ve döngüsel özyinelemeler ile çıkışa eşleyerek zamana bağlı sorunu çözmektedir. LSTM ağları, oluşturulan sistemde zamansal özellikleri öğrenmek için, elde edilen özellik haritası vektörleştirilerek girdi olarak kullanılır. Tam bağlantılı katman mimarisi ile uzamsal korelasyon bilgisinin kaybolmasına neden olur [75]. Tam bağlantılı katman (FC) LSTM'nin bir modifikasyonu olarak evrişim operatörlü evrişimsel LSTM (ConvLSTM) önerildi. ConvLSTM uzamsal özellik haritalarının boyutunu değiştirmeden girdiye-bağımlı durum geçişi ve

bir önceki hücre durumundan bir sonraki hücre durumuna geçişi de evrişim yapıları uygulanarak uzamsal-zamansal bilgiler öğrenilmektedir. Şekil 3.11’de gösterilen LSTM bellek hücre yapısı, giriş kapısı i_t , unutma kapısı f_t ve çıkış kapısı o_t , olmak üzere toplamda 3 adet kapıdan oluşmaktadır. ConvLSTM’nin matematiksel formülü Denklem 3.10’da gösterilmiştir.

$$h_t = g^{LSTM}(X_t, h_{t-1}) = \begin{cases} i_t = \sigma(w_{xi} * X_t + w_{hi} * h_{t-1} + w_{ci} \odot C_{t-1} + b_i) \\ f_t = \sigma(w_{xf} * X_t + w_{hf} * h_{t-1} + w_{cf} \odot C_{t-1} + b_f) \\ \tilde{C}_t = \tanh(w_{xc} * X_t + w_{hc} * h_{t-1} + b_c) \\ C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \\ o_t = \sigma(w_{xo} * X_t + w_{ho} * h_{t-1} + w_{co} \odot C_{t-1} + b_o) \\ h_t = o_t \odot \tanh(C_t) \end{cases} \quad (3.10)$$

Burada, $g^{LSTM}(\cdot)$, t zamanında güncellenen LSTM ağının çıktısıdır. ConvLSTM bloğu için hücrelerde, $X_1, X_2, \dots, X_t$ girdileri, $C_1, C_2, \dots, C_t$ çıktıları ve $h_1, h_2, \dots, h_t$ gizli durumları temsil etmektedir. (σ) sigmoid, ($*$) evrişim operatörü ve ($\odot$) Hadamard çarpımı ifade eder. Her bir kapının bias vektörü b ve her bir kapının ağırlık matrisi w ’dir. Çift yönlü LSTM ağı hem ileri hem de geri zaman yönlerinde zamansal korelasyon bilgisini kapsamlı bir şekilde değerlendirebilir. İleri ve geri LSTM sırası ile Denklem 3.11 ve Denklem 3.12’deki gibi elde edilebilir;


$$\vec{h}_t = g^{LSTM} = (X_t, \vec{h}_{t-1}) \quad (3.11)$$

$$\bar{h}_t = g^{LSTM} = (X_t, \bar{h}_{t-1}) \quad (3.12)$$

Sonuç olarak çift yönlü ConvLSTM (BConvLSTM) çıktısı Denklem 3.13’te verildiği gibi hesaplanır;

$$y_t = \vec{w}_t * \vec{h}_t + \bar{w}_t * \bar{h}_t + b_y \quad (3.13)$$

Burada, $\vec{w}_t$ ve $\bar{w}_t$ sırasıyla ileri ve geri LSTM ağırlıklarını, b_y ise çıktı katmanının biasını ifade etmektedir [63,74,99–102].



Şekil 3.11. LSTM mimarisinin yapısı

3.1.9. Dönüştürücüler ve Swin Transformatör


İlk dönüştürücüler (transformers) yapıları doğal dil işleme için geliştirildi. LSTM gibi modellerin yerini alan dönüştürücüler, başarılı sonuçlar vermiştir. Dönüştürücülerin en önemli özelliği, kelimeler arasındaki ilişkiyi inceleyen öz-dikkat mekanizmasına sahip olmasıdır. Öz-dikkat mekanizması, tüm kelimeler arasındaki ilişkiyi inceleyerek, girdiyi bir bütün olarak ele alır. Bununla birlikte, ESA mimarisindeki evrişim katmanı, filtre boyutu kadar bilgileri işler ve literatürde “bölgesellik” olarak adlandırılan bir problem yaratır. Evrişim işlemi, önceden belirlenmiş filtre boyutlarına göre sınırlı bir bölgedeki bilgileri işleyerek, farklı noktadaki bilgileri ilişkilendirerek elde edilen küresel anlamsal öznitelikleri çıkarmayı sınırlar. Bu problemin çözümü için dönüştürücüler, tüm girdiyi bir bütün olarak işleyerek güçlü küresel anlamsal (uzun menzilli bağlamsal bilgi) öznitelikler elde eder [103]. Dosovitskiy ve arkadaşları [104], 2020 yılında bilgisayarlı görü alanında dönüştürücüleri kullanmak için Vision Transformer (ViT) modelini önermiştir. ViT modeli, parçalama, projeksiyon, konumsal yerleştirme ve çoklu öz-dikkat işlemlerinden oluşmaktadır. Bu işlemler, bilgisayarlı görü alanında dönüştürücülerin yaygın kullanımını sağlamıştır [66,103–107]. Şekil 3.12 (a)’da görüldüğü gibi, standart dönüştürücü, normalleştirme (LayerNorm (LN)), Çok Başlı Öz Dikkat (MSA), ve Çok Katmanlı Algılayıcı (MLP) yapılarından oluşur. Transformatör yapısında MSA ve MLP katmanlarından önce LN katmanı kullanılmıştır. Transformatör çıkışı z Denklem 3.14’teki gibi hesaplanır:

$$\begin{aligned} \hat{z}_1 &= \text{MSA}(\text{LN}(z_{1-1})) + z_{1-1} \\ z_1 &= \text{MLP}(\text{LN}(\hat{z}_1)) + \hat{z}_1 \end{aligned} \quad (3.14)$$

Burada, $\hat{z}_1$ ve z_1 sırasıyla MSA ve MLP çıkış özellik haritalarını ifade etmektedir.

Görüntü işlemede kullanılan ViT dönüştürücü modeli, sınıflandırma alanında başarılı sonuçlar göstermesine rağmen tüm parçaların birbiriyle ilişkilendirilmesi nedeniyle hesaplama sürecinde zaman alıcı ve maliyetlidir. Ayrıca tüm parçaların bir arada ilişkilendirilmesi, özellikle bölütleme ve algılama gibi bilgisayarlı görme sorunlarında zayıf olduğu görülmüştür [105,108,109]. Bu sorunların üstesinden gelmek için swin dönüştürücü (transformatör) modeli önerilmiştir.

Swin transformatör, ViT modelinin hesaplama karmaşıklığını azaltarak bölütleme için daha güçlü bir yapı sergilemektedir. Parçalar arasındaki ilişkiyi değerlendirirken swin transformatör, yerel pencere modelini kullanmaktadır. Pencere tabanlı MSA (W-MSA) ve Kaydırılmış Pencere tabanlı MSA (SW-MSA) modelleri önerilmiştir. Şekil 3.12 (b)’de gösterildiği gibi, swin transformatör yapısında birbirini takip eden W-MSA ve SW-MSA modelleri, geleneksel transformatör modeline göre çok daha düşük işlem maliyetleri sağlamıştır.



Şekil 3.12. (a) Transformer blok yapısı, (b) Swin transformer blok yapısı ve (c) Swin transformer kayan pencere modeli

Swin transformatör modeli, Şekil 3.12 (b)'de görülebileceği üzere iki aşamadan oluşur. İlk aşamada, pencere tabanlı MSA (Window based MSA (W-MSA)) modülü kullanılarak parçalar pencereler içinde gruplandırılır. İkinci aşamada ise pencereler kaydırılarak farklı parçaların bir arada işlenmesi sağlanır. Her kaydırma işleminden sonra, kaydırılmış pencere için kaydırılmış pencere (shifted window) tabanlı tabanlı MSA (SW-MSA) modülü uygulanır. Bu sayede swin transformatör modeli, ViT modeline kıyasla daha az hesaplama maliyeti ile farklı bölgelerdeki parçalar arasındaki ilişkileri değerlendirebilir. Swin transformatör çıkışı (z), Denklem 3.15'te olduğu gibi hesaplanmaktadır [105].


$$\begin{aligned}
 \hat{z}_1 &= \text{WMSA}(\text{LN}(z_{l-1})) + z_{l-1} \\
 z_1 &= \text{MLP}(\text{LN}(\hat{z}_1)) + \hat{z}_1 \\
 \hat{z}_{l+1} &= \text{SWMSA}(\text{LN}(z_l)) + z_l \\
 z_{l+1} &= \text{MLP}(\text{LN}(\hat{z}_{l+1})) + \hat{z}_{l+1}
 \end{aligned} \tag{3.15}$$

Burada, $\hat{z}_1$ ve $\hat{z}_{l+1}$ sırasıyla pencere tabanlı W-MSA ve kayan pencere tabanlı SW-MSA çıkış özellik haritalarını ifade etmektedir.

3.1.9.1. Parça Genişletme

Dönüştürücü modeller, girdi görüntüsündeki nesneleri ve özelliklerini tanımak için öznetelik haritaları üretirler. Bu öznetelik haritaları, her bir pikselin bir özneteliği temsil eden bir vektörle kodlanan vektörleşmiş haritalardır. Dönüştürücü modellerinin çıktı öznetelik haritalarının boyutunu artırmak için Parça Genişletme katmanı önerilmiştir [109]. Başlangıçta bu katmanda, 2 boyutlu $wh \times c$ giriş özellik haritasını $w \times h \times c$ olarak yeniden boyutlandırmaktadır. Ardından, $2 \times c \times s$ filtreli (c =filtre genişliği, s =atlama değeri) bir nokta evrişimi gerçekleştirmektedir. Son olarak, özellik haritası istenen çıktıya göre $2w2h \times sc/2$ veya $2w \times 2h \times sc/2$ boyutlarına


yeniden boyutlandırılmaktadır [66]. Şekil 3.13, parça genişletme katman ayrıntılarını göstermektedir.



Şekil 3.13. Parça genişletme katmanı

3.1.10. Kodlayıcı ve Kod Çözücü Ağlar

ESA mimarileri, sadece sınıflandırma probleminde değil, son zamanlarda bölütleme ve piksel sınıflandırma problemlerinde de başarılı sonuçlar göstermiştir. Özellikle, ESA tabanlı yöntemlerin kullanıldığı bölütleme problemlerinde, önceki yöntemlere kıyasla daha yüksek doğruluk oranları elde edilmiştir. Kodlayıcı ve kod çözücü ağları, çeşitli görüntü işleme problemlerinde başarılı sonuçlar veren derin öğrenme mimarilerindendir. Bu ağ modeli Şekil 3.14’te verildiği gibi kodlayıcı ve kod çözücü modüllerinden oluşmaktadır. Kodlayıcı modülü, genellikle geleneksel ESA mimarilerine benzer şekilde, evrişim, havuzlama ve aktivasyon katmanlarından oluşur. Kod çözücü modülü ise problem için tasarlanmış evrişim, boyut yükseltme ve aktivasyon fonksiyonlarından oluşur. Boyut yükseltme katmanları, kodlayıcı modülünde veri sıkıştırmak için kullanılan havuzlama katmanları yerine kullanılmaktadır. Bu sayede sıkıştırılmış veri boyutları yükseltilerek, kod çözücü ağının çıkışında orijinal boyutlarına dönüştürülmektedir [68,110,111].




Şekil 3.14. Kodlayıcı ve kod çözücü ağlarının genel yapısı

Özellikle piksel bazlı sınıflandırma problemlerinde geliştirilen UNet [110] kodlayıcı-kod çözücü mimarileri ile iyi sonuçlar elde edilmiştir. Ayrıca son yıllarda, UNet’in farklı versiyonları geliştirilmiştir. Örneğin, ResUNet [112], UNet++ [113] ve Attention UNet [114] gibi birçok farklı versiyonları daha yüksek performans sağlamak için farklı özellikler ekleyerek veya ağırlıklandırılarak UNet mimarisini geliştirmişlerdir.

3.1.10.1. UNet Mimarisi

UNet, 2015 yılında Ronneberger ve arkadaşları tarafından geliştirilmiş bir görüntü bölütleme modelidir [67]. UNet, tıbbi görüntüleme gibi sınırlı veri setleri için uygun ve kodlayıcı-kod çözücü mimarisi ile çalışan bir sinir ağıdır. Kodlayıcı bölümü, özellik haritasını küçültmek için sıralı bir şekilde evrişim ve havuzlama katmanlarından oluşurken, kod çözücü bölümü özellik haritasını orijinal boyutuna geri getirmek için boyut yükseltme katmanlarından oluşur. UNet'in en önemli özelliklerinden biri, her bir kodlayıcı katmanına karşılık gelen kod çözücü katmanı ile birleştirilmesidir. Bu atlama bağlantıları, kod çözücü katmanına geçişte, özellik haritasının boyutunu yükseltmek ve kodlayıcı bölümünde kaybedilen bilgiyi geri kazanmak için kullanılır. UNet'in yüksek hassasiyet ve doğruluğa sahip olmasını sağlamaktadır. Şekil 3.15'te UNet mimarisinin genel yapısı gösterilmiştir [110,111,115,116].




Şekil 3.15. Temel UNet mimarisi [110]

3.1.11. Bölgesel Evrişimli Sinir Ağları

Bölgesel Evrişimli Sinir Ağlarının (B-ESA) temel amacı görüntü içerisindeki nesnelerin doğru bir şekilde belirlenmesini sağlamaktır. İlk olarak Girshick ve arkadaşları görüntü içerisindeki nesneleri sınırlayan kutucuklar ve her bir nesnenin etiketlenmesini sağlayan bir B-ESA mimarisi önermişlerdir. Görüntü üzerinden yaklaşık 2000 adet bölge önerisinin ESA ile özellik haritaları çıkarılması çok yavaş çalışmasına neden olmuştur [117]. 2015 yılında Girshick bu problemi ortadan kaldırarak Hızlı B-ESA(HB-ESA) mimarisi önermiştir. Bölge tekliflerini ESA'ya uygulamak yerine, görüntü ilk önce ESA'ya uygulayıp elde edilen özellik haritası üzerinden bölge önerilerine

ayrılma işlemi gerçekleştirilmektedir [118]. HB-ESA, uçtan uca bir dedektör eğitimi yaparak ortak evrimsel özellikleri kullanır. Bu sayede hızlı bir şekilde çalışır ve oldukça iyi sonuçlar elde edilmektedir. Son olarak 2016 yılında Ren ve arkadaşları tarafından daha hassas nesne algılama sonuçları elde edilmesi için Daha Hızlı B-ESA(DHB-ESA) algoritmasını önermişlerdir (Şekil 3.16). HB-ESA mimarisindeki geleneksel seçici arama algoritması yerine, Bölge Öneri Ağı (RPN) algoritmasının entegre edilmesi ile oluşturulmuş bir yöntemdir. Önerilen yöntemde kullanılan RPN modülü ile bölge önerisi, HB-ESA'daki seçici arama algoritmasındaki işlem ve zaman olarak iyileştirmesi gerçekleştirilmiştir. Ayrıca RPN ile önerilen bölge teklif kalitesinin artması doğrudan nesne algılanmasında başarı oranını da iyileştirmektedir [119].



Şekil 3. 16. DHB-ESA mimarisinin yapısı [119]

3.2. Graf Kesim

Graf, $V = \{V_1, V_2, \dots, V_n\}$ pikselleri temsil eden köşe kümesi ve belirli komşu köşe çiftlerini bağlayan $(V_i, V_j) \in E$ kenar kümesinden oluşan, $G = (V, E)$ şeklinde tanımlanmaktadır. Ayrıca her bir kenara bağlanan iki köşe arasındaki özelliğe bağlı, $w(V_i, V_j)$ ağırlıkları da bulunmaktadır. Kenarlarla ilgili bir dizi bilgiye sahip G grafın, nesne/ arka plan olarak adlandırılan A ve B iki ayrık sete bölünmesi ile ilişkilidir [120]. Sonuç olarak optimum bir görüntü bölütlemeye sağlayacak graf kesim maliyetinin, ayırdığı kenarların maliyetlerinin toplamı olarak tanımlanmaktadır. Denklem 3.16 A ve B 'nin en iyi şekilde bölünmesi için kesim değerini en aza indiren bir yaklaşım olarak kullanılabilir.

$$\text{cut}(A, B) = \sum_{p \in A, q \in B} w(p, q) \quad (3.16)$$

Burada p ve q görüntüdeki piksellerin oluşturduğu iki farklı bileşen çiftlerini ifade eder. Görüntüdeki gürültü gibi bozucu etkenler çoğu zaman bölütlemeyi zorlaştırmaktadır. Çeşitli optimizasyon yaklaşımları ile bu sorun ortadan kaldırılmaktadır.

Görüntü bölütlemesi piksel etiketleme problemi olarak karşımıza çıkmaktadır. Karşılaşılabilecek olan birçok bölütleme problemi enerji minimizasyonu ile çözüme ulaşılabileceği önerilmiştir. Greig ve arkadaşları [121], görüntü iyileştirme problemini çözmek için minimum kesim (min-cut) ve maksimum akış (max-flow) algoritmalarını kullanarak enerji minimizasyonu yapabileceklerini öne sürmüşlerdir. Bu algoritmalar, bir grafta belirli bir enerji fonksiyonunun minimizasyonunu hesaplamak için kullanılır. Görüntü işlemede, enerji fonksiyonu genellikle iki terimden oluşur: verilerin terimi ve sınır terimidir. Veriler terimi, girdi görüntüsünü çıktı görüntüsüne eşleştirmeye çalışırken, sınır terimi benzer yoğunluktaki pikseller arasındaki farkları cezalandırır. Minimum kesim / maksimum akış algoritmaları, bu iki terimi hesaba katarak enerji fonksiyonunu minimize etmek için kullanılır [122]. Sonuç olarak, görüntü iyileştirme probleminde bu algoritmalar kullanılarak, bir girdi görüntüsünden en iyi çıktı görüntüsünü üretmek için sınır terimi kullanılarak süreksizlikleri cezalandırmak mümkün olacağını öne sürmüşlerdir. Boykov ve arkadaşları [123] ayrık değişkenler kümesi için tanımlanan görüntülerde, önerilen kombinasyonel minimum kesim/ maksimum akış graf kesim algoritması ile bölütleme problemini çözümleyecek bir yöntem oluşturmuştur. Denklem 3.17’de minimum kesim ile minimize edilen enerji fonksiyonu verilmiştir.

$$E(L) = \lambda \sum_{p \in I} R(p, L_p) + \sum_{\{p, q\} \in N} B(p, q) \delta(L_p \neq L_q) \quad (3.17)$$

$$\delta(L_p \neq L_q) = \begin{cases} 1; & L_p \neq L_q \\ 0; & L_p = L_q \end{cases}$$


Burada $L = \{I_1, I_2, I_3, \dots, I_p\}$ görüntüdeki piksel kümesini, N görüntüdeki tüm piksellerin oluşturduğu (p, q) piksel çiftlerini temsil etmektedir. $L_p = 1$ durumu için etiketlenen pikseller nesne, $L_p = 0$ durumu için ise arka plan olarak ayrık değişkenler kümesini oluşturmaktadır. $\lambda > 0$ katsayısı, bölgesel terim $R(p, L_p)$, sınır terimi $B(p, q)$ arasındaki göreceli bir önemi belirtir. Denklem 3.18’deki bölgesel terim $R(p, L_p)$ aşağıdaki gibi tanımlanır;

$$R(p, L_p) = -\ln \Pr(I_p | L_p) \quad (3.18)$$

Burada $\Pr(I_p | L_p)$, L_p etiketine verilen I_p yoğunluğunun olasılığıdır. Aynı zamanda eşitlikteki $R(p, L_p)$ ifadesinde p ’nin L_p ’ye uygun olma olasılığını belirttiği için, yanlış etiket ataması tespit edilebilir. Etiketlerin doğru ataması bölgesel terimi minimize edecektir [124]. Denklem 3.18’de verilen sınır terimi $B(p, q)$ için sınır cezalarını aşağıdaki verilen Denklem 3.19 ile tanımlanabilir.

$$B(p, q) \propto \exp \left(-\frac{(I_p - I_q)^2}{2\sigma^2} \right) / \|p - q\| \quad (3.19)$$

Burada $\|p - q\|$ ile gösterilen ifade p ve q arasındaki Öklid mesafesini, σ ise görüntüde tahmin edilecek gürültünün standart sapmasını ifade etmektedir. Bu sayede sınır teriminin benzer yoğunluktaki pikseller arasındaki süreksizliklerini büyük ölçüde cezalandırmaktadır. Sonuç olarak graf kesim problemi, minimum enerji formuna dönüştürülerek iyileştirmeler gerçekleştirilmiştir. Böylece, görüntüdeki benzer yoğunluktaki pikseller arasındaki farklar azaltılarak daha pürüzsüz bir görüntü elde edilir. Şekil 3.17’de nesne (S) ve arka plan (T) iki terminal düğüm olarak modellenen graf kesim bölütlemesi için 3×3’lük bir örnek görüntü gösterilmiştir.



Şekil 3.17. Bir 3×3 s/t graf kesim bölütleme modeli [125]


3.3. Sınıflandırma Modelleri

Bu tez çalışmasında dış materyallerin tespiti için Destek Vektör Makineleri (DVM), K-En Yakın Komşu (k-NN), Karar Ağaçları (KA) ve Naïve Bayes (NB) kullanılmıştır. Bu bölümde en iyi sonucun elde edildiği DVM sınıflandırıcısı için detaylı bilgi verilmektedir. Ayrıca tezde kullanılan diğer sınıflandırıcı yöntemleri de açıklanmaktadır.

DVM sınıflandırıcısı, Vapnik tarafından geliştirilmiş denetimli bir yapay sinir ağı algoritmasıdır. Önerilen model hem sınıflandırma hem de regresyon problemlerinin çözümünde başarılı sonuçlar vermektedir. 1 boyutlu bir uzayda x vektörü sınıflandırılacak deseni ve $y (\pm 1)$ ise etiketleri belirtmektedir. Ağırlık vektörü (w) ve eğilim değeri (b) gibi iki değişkene sahip hiper düzlem parametreleri sınıflar arasındaki simetrik aralığı maksimize etmek için ayarlanır. Girdi modellerinin lineer olarak ayrılabilir olduğu en basit durum Denklem 3.20’de verilmiştir [126]. Şekil 3.18’de DVM’nin temel yapısı gösterilmiştir. İki veri kümesi arasındaki uzaklık $2/\|w\|$ olarak hesaplanır. Bu iki hiperdüzlem arasındaki uzaklığı maksimuma çıkarmak için, $\|w\|$ ’nin aşağıdaki şartlara göre minimuma indirilmesi gerekmektedir [127,128].

$$\min \frac{1}{2} \|w\|^2$$

$$f_{(x)} = y_i (w^T \cdot x_i + b) \geq 1, i = 1, \dots, l \quad (3.20)$$



Şekil 3.18. DVM hiperdüzlem ayırımı

Lineer sınıflandırıcının bir uzantısı olan lineer olmayan DVM sınıflandırıcısında x giriş modelini daha yüksek boyutlu bir uzaya aktarmak için Denklem 3.21’de belirtilen lineer olmayan bir operatör $\Phi(\cdot)$ kullanılır [2].

$$f_{(x)} = y_i(w^T \cdot \Phi(x_i) + b) \quad (3.21)$$

Denklem 3.21, dönüştürülmüş veri $f_{(x)}$ açısından doğrusaldır, ancak orijinal veri x için doğrusal değildir. Doğrusal olmayan dönüşüm ile birlikte karar fonksiyonunun parametreleri aşağıda verilen Denklem 3.22’deki minimizasyon kriteri ile belirlenmektedir [3].

$$\begin{aligned} \min J(w, \xi) &= \frac{1}{2} ||w||^2 + C \sum \xi_i, \quad i = 0, 1, \dots, l, \\ y_i(w^T \cdot \Phi(x_i) + b) &\geq 1 - \xi_i, \quad \xi_i \geq 0; \quad i = 1, 2, \dots, l \end{aligned} \quad (3.22)$$

DVM’de çekirdek işlevi girdi vektörünün doğrusal olmayan yüksek boyutlu bir özellik uzayında eşleşmesinde önemli bir rol oynamaktadır. Çekirdek işlevi seçilirken doğrusal olmayan bir eşlemenin iç çarpımı ile ilişkisinin olup olmadığından emin olmak önemlidir. $K(\cdot)$ çekirdeğinde tanımlanan her kare integrallenebilir $g(\cdot)$ işlevi için çekirdek, Denklem 3.23 verilen Mercer teorem koşulunu sağlamaktadır [3].

$$\iint K(x, y)g(x)g(y)dx dy \geq 0 \quad (3.23)$$

Literatürde farklı alanlarda yapılan çalışmalarda sınıflandırma problemi için çeşitli kernel fonksiyonları kullanılmıştır. Mercer koşulunu sağlayarak en yaygın kullanılan çekirdek işlevi polinomlar ve radyal tabanlı fonksiyonlar (RBF) içermektedir. Polinom çekirdeği Denklem 3.24 gibi tanımlanmaktadır.

$$K(x, y) = (x^T + 1)^p \quad p > 0 \quad (3.24)$$

Son olarak çekirdek işlevinin eklenmesi ile DVM sınıflandırıcının karar fonksiyonu Denklem 3.25'teki gibi tanımlanır:

$$f(x) = \text{sign}(\sum_{i=1}^N y_i a_i K(x_i, x) + b) \quad (3.25)$$

Burada optimizasyon probleminin çözümünde, x_i i veri noktası, x test vektörü, b bias değeri, y veri noktasının sınıfı ve a_i , x_i eğitim örneği ile ilişkili Lagrange çarpanıdır [129–132]. k-NN sınıflandırıcı, nesnelerin bir birine yakınlık ilişkisine göre sınıflandırma yapan denetimli bir öğrenme algoritmasıdır. Yöntemin çalışma prensibi dahil edilecek gözlemin, oluşturulmuş eğitim kümesindeki her bir gözlem değerleri ile uzaklıkları hesaplanmaktadır. Belirlenen en yakın k parametresine göre baskın bir kategori altında sınıflandırır. Ancak, denetimli bir öğrenme olması nedeniyle gürültü parametrelerinin varlığı, sorunlara yol açabilme potansiyeline sahiptir [133].

KA sınıflandırıcı, bir ağaç yapısı biçiminde sınıflandırma veya regresyon problemleri üzerine modeller oluşturan bir algoritmadır. Eğitim kümesindeki veriler ile kurallar çıkartarak, yeni verilerin hangi sınıfa ait olduğuna karar veren sezgisel bir yöntemdir. Denetimli öğrenme algoritması, doğru tahmini elde etmek için bir dizi if-then yapısına tabi tutularak en optimal sıralamayı bulmaya çalışan bir yaklaşımdır [134].

NB sınıflandırıcı, Thomas Bayes tarafından geliştirilen Bayes teoremine dayalı, sınıflandırma problemlerinin çözümü için kullanılabilecek olasılıksal bir yaklaşımdır. NB yönteminin en dikkate değer özelliklerinden biri, sınıf içindeki verilerin özniteliklerinin birbirinden bağımsız olduğunu varsaymasıdır. Bu varsayım, sınıflandırma sürecinde güçlü bir varsayımsal temel oluşturarak etkili sonuçlar elde etmeyi sağlar. Algoritmanın karmaşık olmaması, küçük veri kümesiyle kolayca eğitilir yapıda olması ve iyi performans göstermesinden dolayı kullanışlıdır [135].

3.4. Sınıflandırma Performans Metrikleri

Bu tez çalışmasında önerilen yöntemlerin performans değerlendirmelerinde doğruluk, duyarlılık, kesinlik, birleşim üzerinde kesişme oranı (IoU) ve F1-skoru metrikleri ile gerçekleştirilmiştir. Doğruluk, bir modelin doğru tahminlerinin, tüm tahminlerine oranıdır. Duyarlılık, gerçek pozitiflerin tespit edilme oranını ifade eder. Aynı zamanda hassasiyet olarak da adlandırılmaktadır. Duyarlılık, özellikle tıp ve güvenlik alanlarında önemli bir performans metriğidir, çünkü yanlış negatiflerin sayısının mümkün olduğunca düşük olması gerekmektedir. Kesinlik, modelin pozitif olarak tahmin ettiği örneklerin kaçının gerçekten pozitif olduğunu belirtmektedir. F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır. Doğruluğu tek başına değerlendirmek yerine hem kesinlik hem de duyarlılık metriklerini hesaba katarak, modelin performansını daha iyi bir şekilde ölçmek için kullanılan bir performans metriğidir. IoU metriği,

gerçek etiket (maskeli görüntü) ile tahmin edilen piksel haritası arasındaki örtüşme yüzdesini ölçmek için kullanılan bir yöntemdir [50,115,136]. Bu şekilde doğru sınıflandırılan piksellerin toplamı örtüşen alanı oluşturur. Bu performans ölçütleri şu şekilde tanımlanır:

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3.26)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3.27)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (3.28)$$

$$F1 - \text{skoru} = \frac{2 \times \text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (3.29)$$

$$IoU = \frac{DP}{DP+YP+YN} \quad (3.30)$$

Bu denklemlerde kullanılan ifadeler sırasıyla DP doğru-pozitif, DN doğru-negatif, YP yanlış-pozitif ve YN yanlış-negatif anlamına gelmektedir.


ROC (Alıcı İşlem Karakteristiği) eğrisi, sınıflandırma modellerinin performansını değerlendirmek için kullanılan bir metriktir. ROC eğrisi, hassasiyet (doğru pozitif oranı) ile özgüllük (yanlış pozitif oranı) arasındaki ilişkiyi gösteren bir grafikdir. Sınıflandırma modeli, bir eşik değeri belirleyerek pozitif ve negatif sınıfları ayırır. ROC eğrisi, bu eşik değerini değiştirerek modelin farklı hassasiyet ve özgüllük değerleriyle nasıl performans gösterdiğini gösterir. ROC eğrisinde, eksenlerdeki değerler genellikle 0 ile 1 arasında değişen olasılık veya skor değerleridir. ROC eğrisi, bir sınıflandırma modelinin performansını görselleştirmek ve farklı modellerin karşılaştırılmasını sağlamak için kullanılır. Ayrıca, ROC eğrisi altındaki alan (AUC), sınıflandırma modelinin genel performansını ölçen bir metrik olarak kullanılmaktadır. AUC değeri 1'e ne kadar yakınsa, modelin daha iyi bir sınıflandırma performansı olduğu anlaşılmaktadır [137].

4. PANORAMİK DİŞ RÖNTGEN GÖRÜNTÜLERİNDE DHB-ESA, GRAF KESİM VE ŞEKİL ÖZELLİKLERİNE DAYALI DİŞ MATERYAL TESPİTİ UYGULAMASI


Bu bölümde, diş materyallerinin tespiti için önerilen derin öğrenme tabanlı yeni yaklaşım ile deneysel sonuçları yer almaktadır. Çalışma panoramik görüntülerde kaplama, köprü ve dolgulu dişlere derin öğrenme sistemi uygulayarak görüntüyü inceleyen, diş hekimine kolaylık sağlamayı amaçlamaktadır. Bu doğrultuda diş materyal tespiti için iki aşamadan oluşan derin öğrenme tabanlı bir algılama modeli önerilmiştir. Mevcut tez çalışmasındaki uygulama köprü, kaplama ve dolgu gibi diş malzemelerinin tespiti için yapılan öncü çalışmalardan birisidir.

4.1. Veri Seti

Diş veri seti dolgu, kaplama ve köprü operasyonlarının uygulandığı 160 panoramik görüntüden oluşmaktadır. Özel diş kliniklerinde toparlanan panoramik görüntülerin, uzman bir diş hekimi yardımı ile etiketleme işlemi gerçekleştirilmiştir. Şekil 4.1’de, veri setindeki birkaç panoramik görüntü verilmiştir. Bunun ile birlikte Şekil 4.2’de de karşılık gelen maske (etiket, yer-gerçeği) görüntüleri bulunmaktadır.




Şekil 4.1. Veri setindeki bazı panoramik diş görüntü örnekleri



Şekil 4.2. Şekil 4.1’de verilen görüntülerin maskesi

4.2. Önerilen Yöntem

Önerilen yöntemler Şekil 4.3 ve Şekil 4.4’te gösterilmiştir. Bu şekillerde görüldüğü gibi, önerilen yöntem iki bağımsız bölümden oluşmaktadır. Birinci bölümde daha DHB-ESA yaklaşımı kullanılarak panoramik görüntülerdeki diş bölgeleri belirlenir (Şekil 4.3). Önerilen çalışmanın ikinci bölümünde görüntü bölütleme, özellik çıkarma ve özellik sınıflandırma işlemleri gerçekleştirilmektedir (Şekil 4.4).



Şekil 4.3. Önerilen yöntemin ilk kısmı

Panoramik diş görüntüleri, ilk olarak gürültü giderme ve kontrast artırma yaklaşımları kullanılarak bir ön işlemden geçirilmiştir. Önceden işlenmiş görüntüler daha sonra DHB-ESA’ya giriş olarak verilmektedir. Panoramik diş görüntülerde diş bölgesini algılamak için DHB-ESA kullanılmaktadır. DHB-ESA yapısında temel ağ olarak AlexNet mimarisi kullanılmıştır. AlexNet

mimarisinin son üç katmanı kaldırılmış ve eldeki problem için DHB-ESA yönteminin oluşturulması için yeni tam bağlantılı, softmax ve sınıflandırma katmanları eklenmiştir. Tablo 4.1, AlexNet'in mimarisini göstermektedir. AlexNet mimarisi, üçünü maksimum havuzlama katmanlarının takip ettiği beş evrişim katmanından oluşmaktadır. AlexNet mimarisinin girişi, 227×227 boyutunda bir RGB görüntüsüne sahiptir. Birinci evrişim katmanında çekirdek boyutu 11×11 olan 96 filtre kullanılmıştır. Böylece giriş görüntüsünün boyutu $55 \times 55 \times 96$ olmaktadır. İkinci evrişim katmanında, önceki maksimum havuzlama katmanının çıkışına çekirdek boyutu 5×5 olan 256 filtre uygulanmaktadır. Diğer evrişim ve maksimum havuzlama katmanlarında da benzer yaklaşım uygulanmaktadır.

Tablo 4.1. AlexNet mimarisinin kaydedilmiş katmanları


Katman	Çıktı Öznitelik Boyut	Çekirdek Boyutu
Giriş	$227 \times 227 \times 3$	-
Evrişim	$55 \times 55 \times 96$	11×11
Maksimum Havuzlama	$27 \times 27 \times 96$	3×3
Evrişim	$27 \times 27 \times 256$	5×5
Maksimum Havuzlama	$13 \times 13 \times 256$	3×3
Evrişim	$13 \times 13 \times 384$	3×3
Evrişim	$13 \times 13 \times 384$	3×3
Evrişim	$13 \times 13 \times 256$	3×3
Maksimum Havuzlama	$6 \times 6 \times 256$	3×3

Son maksimum havuzlama katmanından sonra bölge öneri ağı (RPN), DHB-ESA mimarisinde konumlandırılır. RPN, AlexNet'in son maksimum havuzlama katmanının çıkışından bir dizi bağlantı kutusu oluşturur. Bağlantı kutuları, bir ölçek ve en boy oranıyla ilişkilendirilmiş kayan bir pencerenin ortasına yerleştirilmiştir. Üç bağlantı kutusu ölçeği ve üç bağlantı kutusu oranı kullanılır ve bu, her kayan pencere konumunda dokuz bağlantı noktası üretmektedir. Son olarak, RPN tüm bağlantı kutularını dikkate alır ve her bir bağlantı noktası için iki çıktı verir. İlgi Alanı Havuzu (ROI) ve Tam Bağlantılı (FC) katmanlar daha sonra ilgilenilen nesneler olan sınırlayıcı kutuları almak için uygulanır. İlki, bir referans noktasının bir nesne olma olasılığı değeridir. İkincisi, referans noktalarını nesneye daha iyi uyum sağlamak için sınırlayıcı kutu regresyonu yaparak ayarlamaktır. Bu değerler kullanılarak dış bölgeleri belirlenir.

DHB-ESA'nın, belirli bir panoramik dış röntgen görüntüsü girişi için birden fazla dış bölgesi üretmesi oldukça olasıdır. Ancak tam olarak hangi bölgenin dış olduğunu belirlemek için bir ROI düzeltme mekanizması uygulanmaktadır. Bu mekanizma, daha hızlı DHB-ESA'nın çıkış sınırlayıcı

kutularının alanlarına dayanmaktadır. Gerçek diş bölgesi, üretilen sınırlayıcı kutunun kapladığı maksimum alana sahip olmalıdır ve sınırlayıcı kutuların geri kalanı kaldırılır. Böylece, daha hassas bir diş bölgesi belirlemek mümkün hale gelmektedir.

Diş bölgesi belirlendikten sonra, giriş panoramik diş görüntüsünün ikili görüntüsünü elde etmek için Graf Kesim (GK) görüntü bölütleme yaklaşımı uygulanmaktadır. Şekil 4.4'te görüldüğü gibi panoramik diş görüntülerde diş dolgusu, köprüsü ve kaplama bölgeleri diğer kısımlara göre daha parlak görünmektedir. Bu nedenle, GK yaklaşımı, girdi ROI'sinin ikili hale getirilmesinde oldukça etkilidir.



Şekil 4.4. Önerilen yöntemin ikinci kısmı

Girdi görüntüsünün ikili hale getirilmesinden sonra, her bölütlenmiş ikili nesne için şekil tabanlı bir özellik çıkarımı uygulanır. Bu amaçla, parçalanmış her bir ikili nesne için ana eksen uzunluğu, küçük eksen uzunluğu, eksantriklik, yönelim, kapsam, çevre, sağlamlığı ve dairesellik özellikleri hesaplanmaktadır. Bir ikili bölgenin ana eksen ve küçük eksen uzunlukları, sırasıyla aynı normalleştirilmiş ikinci merkezi momentlere sahip olan elipsin ana ve küçük ekseninin uzunlukları olarak tanımlanır. Genellikle nesnenin yönelimini tanımlamaktadır. Eksantriklik, bir nesnenin bir elipsin ne kadar yassı olduğunu ölçen bir şekil tabanlı öz niteliktir. İkili bir nesnenin eksantrikliği, elipsin odakları ile ana eksen uzunluğu arasındaki mesafenin oranı olarak tanımlanır. İkili bir nesnenin oryantasyonu, x ekseni ile aynı ikinci momentlere sahip elipsin ana ekseni arasındaki açı olarak tanımlanır. İkili bir nesnenin kapsamı, bölgedeki piksellerin toplam sınırlayıcı kutudaki piksellere oranı olarak tanımlanır. İkili bölgenin çevresi, bölgenin sınırındaki piksellerin sayısına karşılık gelen mesafedir ve genellikle bölgenin uzunluğunu, karmaşıklığını ve benzer özelliklerini ölçmek için kullanılır. Bir ikili bölgenin sağlamlığı, aynı zamanda ikili bölgede bulunan dışbükey gövdedeki piksellerin oranı olarak tanımlanır. Son olarak dairesellik, ikili bir nesnenin yuvarlaklığı olarak tanımlanır.

Elde edilen özellikler daha sonra DVM, k-NN, KA ve NB yöntemleri gibi çeşitli makine öğrenme algoritmaları kullanılarak sınıflandırılmaktadır.

Önerilen yöntemin adımları şu şekilde verilmiştir;

Adım 1: DHB-ESA yöntemini kullanarak giriş panoramik görüntüsünün gereksiz kısımlarını ortadan kaldırın. Birden fazla algılanan ROI varsa, nihai ROI'yi elde etmek için ROI düzeltmesini uygulayınız.

Adım 1.1. DHB-ESA'yi kullanmak için sırasıyla ESA'nın katmanlarını tasarlayın, bir eğitim veri seti kullanın, ROI'yi etiketleyin ve ağı eğitiniz.

Adım 2: Görüntüyü arka plan ve ön plan nesneleri olarak bölümlere ayırmak için GK'yı kullanın.

Adım 3: Her bir ön plan nesnesini elde etmek için morfolojik süreçleri kullanın ve onlardan özellikleri çıkarınız.


Adım 4: Ön plan nesnelerinin sınıf etiketini belirlemek için DVM gibi bir makine öğrenimi yaklaşımı kullanınız.

4.3. Deneysel Çalışmalar ve Sonuçları


Deneysel çalışmalar, 8 GB RAM'e sahip NVIDIA Quadro M4000 GPU ile donatılmış bir bilgisayarda gerçekleştirilmiştir. Tüm kodlamalar için MATLAB yazılımı kullanılmıştır. Bir önceki bölümde bahsedildiği gibi söz konusu DHB-ESA mimarisinin temel ağı için önceden eğitilmiş AlexNet modeli kullanılmıştır. DHB-ESA modelinin eğitiminde momentum (SGDM) optimize edici ile stokastik gradyan iniş kullanıldı. Maksimum epoch ve mini batch gibi eğitim parametreleri sırasıyla 100 ve 4'e ayarlandı ve ilk öğrenme oranı, 0.0001'lik öğrenme oranı düşüşüyle 0.001'e ayarlandı. Ek olarak, pozitif ve negatif örtüşme aralıkları sırasıyla [0- 0,3] ve [0,6- 1] aralıklarına ölçeklendi. Her bir eğitim görüntüsünden rastgele örneklenecek bölge önerisi sayısı [256 128] olarak seçilmiştir. Kutu piramit ölçek faktörü olarak adlandırılan kutu piramit ölçeği de 1.2 olarak ayarlanmıştır.

Şekil 4.5, DHB-ESA mimarisinin bazı örnek çıktılarını göstermektedir. Sarı sınırlayıcı kutular, panoramik dış görüntülerde algılanan dış bölgesini göstermektedir. Şekil 4.5'te görüldüğü gibi, DHB-ESA yöntemi genellikle dış bölgesinin gerçek yerini saptasa da bazı yanlış konumları da saptamıştır.

Dış bölgesinin tam yerini tespit etmek için, önerilen yöntemin şematik gösteriminde gösterildiği gibi bir ROI düzeltme adımı uygulandı. DHB-ESA yönteminin düzeltilmiş çıktıları Şekil 4.6'da verilmiştir. Şekil 4.6'da görüldüğü gibi uygulanan düzeltme adımı dış panoramik görüntülerde dış bölgesinin tam yerini belirleyebilmiştir. Ayrıca düzeltilmiş ROI, GK görüntü bölütlemesinde kullanıldı ve dış panoramik görüntünün geri kalanı göz ardı edildi.




Şekil 4.5. DHB-ESA modelinin bazı örnek çıktıları




Şekil 4.6. DHB-ESA modelinin ROI düzeltilmiş çıktıları

Daha önce bahsedildiği gibi, ROI düzeltilmiş görüntünün ikili hale getirilmesinde GK yaklaşımı kullanılmıştır. Aslında bölütlemeye geleneksel eşikleme yaklaşımları da dikkate alınmış ancak elde edilen sonuçlar GK yöntemi kadar iyi sonuçlar vermemiştir. GK, bir giriş görüntüsünü ön plan ve arka plan bölgelerine ayıran yarı otomatik bir yöntemdir. GK yönteminde kullanıcı, ön plan ve arka plan bölgelerini belirlemek için görüntü üzerine çizgiler çizer. Bahsedilen prosedürün çizimi Şekil 4.7’de gösterilmektedir.



Şekil 4.7. GK yönteminin karalamaları


Şekil 4.7’de gösterildiği gibi, yeşil karalamalar ön bölgeleri (diş dolgusu, diş köprüsü ve diş kaplaması) belirtmek için, kırmızı karalamalar ise arka plan bölgelerini göstermek için kullanılmıştır. Camgöbeği rengine renklendirilen bölgeler, GK yönteminin bölütleme sonucunu gösterir. Şekil 4.8’de görüldüğü gibi, GK yöntemi girdi düzeltmeli ROI görüntüsünün ikili hale getirilmesinde oldukça etkiliydi.



Şekil 4.8. Özellik çıkarma için blob tespiti


Daha önce belirtildiği gibi, ana eksen uzunluğu, küçük eksen uzunluğu, eksantriklik, yönelim, kapsam, çevre, sağlamlılık ve dairesellik olmak üzere sekiz şekil tabanlı özellik kullanılmıştır. Şekil 4.9, 2B çizimde ana eksen uzunluğu özelliğinin küçük eksen uzunluğu özelliklerine göre dağılımını göstermektedir. Mavi numune noktaları diş köprüsü sınıfını gösterirken, kırmızı ve yeşil numune noktaları sırasıyla diş dolgusu ve diş kaplaması sınıflarını göstermektedir.

Tablo 4.2, özelliklerin her bir sınıfa göre dağılımını göstermektedir. Satırlar özellikleri, sütunlar ise sınıfları gösterir. Tablo 4.2’de görüldüğü gibi, her sınıfın öznelik dağılımları ayırt edici özelliklere sahiptir. Dolgu sınıfı için çıkarılan öznelikler genel olarak normal dağılıma sahipken, diş köprüsü ve diş kaplama sınıfları için özneliklerin dağılımı normal ve üsteldir.




Şekil 4.9. 2B çizimde ana eksen uzunluğu özelliğinin küçük eksen uzunluğu özelliklerine göre dağılımı

Tablo 4.2. Sınıflar için özelliklerin dağılımı



Tablo 4.2. Sınıflar için özelliklerin dağılımı (devamı)




Deneylerde beş çapraz doğrulama yöntemi kullanıldı. Performans ölçümleri için sınıflandırma doğruluğu hesaplanmıştır. Veri setinde 296 adet diğ dolgusu, 48 adet köprü ve 143 adet kaplama bulunmaktadır. MATLAB toolbox DVM, k-NN, KA ve NB sınıflandırıcıları kullanılmıştır. Bu sınıflandırıcılar için varsayılan ayar parametreleri kullanılmıştır. Her bir sınıflandırıcı için ortalama sınıflandırma doğrulukları Tablo 4.3'te verilmiştir.

Tablo 4.3. Yapılan sınıflandırmalar için ortalama doğruluk yüzdeleri

Sınıflandırma	Ortalama doğruluk (%)
DVM	92.8
k-NN	89.9
KA	89.7
NB	89.5


Tablo 4.3'de görüldüğü gibi, en yüksek doğruluk skoru %92.8 ile DVM sınıflandırıcısı ile elde edilmiştir. k-NN, KA ve NB sınıflandırıcıları sırasıyla %89.9, %89.7 ve %89.5 ortalama doğruluk skoru vermiştir. En kötü ortalama doğruluk skoru NB sınıflandırıcısı tarafından %89.5 olarak üretilmiştir. DVM sınıflandırıcısı için karışıklık matrisi Şekil 4.10'da verilmiştir. Şekil 4.10'da diğ köprüsü, diğ kaplaması ve diğ dolgusu için sırasıyla 0, 1 ve 2 etiketleri kullanılmıştır.



Şekil 4.10. DVM sınıflandırıcısı için elde edilen karışıklık matrisi


Şekil 4.10’da dış köprülerinin 8’inin dış kaplama, dış köprülerinin 15’inin dış dolgusu olarak sınıflandırıldığı görülmektedir. Ayrıca 1 ve 4 dış kaplama örnekleri sırasıyla köprü ve dış dolgusu olarak sınıflandırıldı. Son olarak, dış dolgusu örnekleri 6 ve 1 sırasıyla dış köprüsü ve dış kaplaması olarak sınıflandırıldı. Şekil 4.10’daki önemli bir gözlem, yanlış sınıflandırmaların çoğunlukla dış köprüsü örneklerinde meydana gelmesiydi.

Şekil 4.11, DVM sınıflandırıcısı için ROC eğrisini göstermektedir. Şekil 4.11’de görüldüğü gibi, ROC eğrisi yaklaşık 0.52 skora kadar çıkar ve ardından bir yay çizerek 1 değerine kadar çıkmaktadır. ROC performans başarımlar değeri 0.92’dir.



Şekil 4.11. DVM sınıflandırıcısı için ROC eğrisi

Önerilen yöntemin deneysel çalışmalarında UNet, SegNet ve Mask RCNN gibi mevcut yöntemlerden bazılarıyla daha fazla karşılaştırması yapılmıştır. Bu yaklaşımlar derin ESA tabanlı görüntü bölütleme yaklaşımlarıdır. Bu yöntemlerin uygulanmasında Matlab Deep Learning aracı kullanılmıştır. Uygulamalarda varsayılan parametreler hedef alınmıştır. Elde edilen sonuçlar Tablo 4.4’te verilmiştir. Tablo 4.4’te görüldüğü gibi UNet ve SegNet mimarileri hemen hemen benzer doğruluk sonuçları verirken, Mask RCNN yaklaşımı UNet ve SegNet başarımlarına göre biraz daha kötü sonuç vermiştir. Şekil 4.12’de karşılaştırılan yöntemlerin bölütleme sonuçları görülmektedir. Birinci satır maske (etiket, yer-gerçeği) bölütlemelerini gösterirken, ikinci, üçüncü, dördüncü ve beşinci satırlar sırasıyla önerilen model olan UNet, SegNet ve Mask RCNN’nin başarımlarını göstermektedir.



Şekil 4.12. Görsel bölütleme sonuçlarının karşılaştırılması

Tablo 4.4. Diğer yöntemler için ortalama doğruluk yüzdeleri


Metot	Ortalama doğruluk (%)
Önerilen Yöntem	92.8
UNet	90.9
SegNet	91.7
Mask RCNN	87.5

5. PERİAPİKAL DİŞ RÖNTGEN GÖRÜNTÜLERİNDE SKOR TABANLI ÇOK GİRİŞLİ DERİN EVRİŞİMSEL SİNİR AĞINA DAYALI DİŞ ÇÜRÜĞÜ TESPİTİ UYGULAMASI

Dış çürükleri, yaygın olarak karşılaşılan diş hastalıkları arasında yer almaktadır. Bu çürüklerin tespiti genellikle diş hekimleri tarafından panoramik ve periapikal görüntüleme tekniklerine dayanarak manuel olarak gerçekleştirilir. Bu yöntemler, çürüklerin erken teşhis edilmesini ve tedavi sürecinin başlatılmasını sağlayarak hastaların ağız sağlığının korunmasında önemli bir rol oynamaktadır. Çoğu zaman radyografide görülen çürük diş teşhisi doğru yapılamaz çünkü mevcut diş çürükleri hekimin deneyimsizliği veya yoğun hasta yükü nedeniyle gözden kaçabilir. Bu durum çürüklerin ilerlemesine, ilerlemiş diş enfeksiyonlarına ve diş kaybına neden olabilir. Olumsuzlukların önüne geçebilmek ve diş hekimlerinin teşhis koymalarını kolaylaştırmak için periapikal diş görüntülerini kullanarak diş çürüklerini tespit etmek için yeni bir skora dayalı çok girişli derin evrişimli sinir ağı topluluğu sunuldu. Çalışmanın amacı, periapikal görüntülere dayalı olarak diş çürüğünün otomatik teşhisinde diş hekimlerine yardımcı olmak için derin evrişimli sinir ağlarının yeteneğini belirlemektir. Önerilen modelde, ham çürük görüntülerini keskinleştirmek için görüntü işleme tekniklerini kullanmıştır. Daha sonra ham ve işlenmiş görüntüler kullanılarak çok girişli derin evrişimli sinir ağı tasarlanmış ve eğitim süreci gerçekleştirilmiştir. Son olarak, çok girişli ESA mimarisinin softmax katmanları, skor düzeyi tabanlı algoritma ile birleştirilmiştir. Elde edilen deneysel sonuçlar diş çürüklerinin sınıflandırılması için önerilen modelin diş hekimlerinin performanslarına önemli katkılar sağlayacağını ortaya koymuştur.

5.1. Veri Seti

Bu çalışmada geçmişe yönelik çalışmalarda olduğu gibi iki özel ağız ve diş sağlığı kliniğinden periapikal radyografi cihazları (Planmeca Intra, Helsinki, Finlandiya), (MyRay, Imola, İtalya) kullanılarak elde edilen görüntüler değerlendirildi. 310 hastaya ait toplam 380 periapikal görüntü analiz edildi. Bulanık görüntüler veya kırık, kist ve enfeksiyon içeren görüntüler dahil 40 görüntü çalışma dışı bırakıldı. 380 görüntüden 340 periapikal görüntü çalışmaya dahil edilmiştir. Hastalardan elde edilen periapikal radyografi görüntülerini içeren bir veri seti oluşturuldu. Bu radyografiler 150 çürük diş ve 190 çürük olmayan dişin görüntülerini içermektedir. Bu veri seti bir diş hekimi tarafından kontrol altında elde edilmiştir. Bu görüntüler gri kanalları ve değişken boyutlardaydı. Şekil 5.1, veri setinden diş periapikal görüntülerin bazı örneklerini göstermektedir.




Şekil 5.1. Bu uygulamada kullanılan periapikal diş görüntüleri


5.2. Önerilen Yöntem

Bu çalışma, periapikal diş görüntülerini kullanarak diş çürüklerini tespit etmek için yeni bir skora dayalı çok girişli derin evrişimli sinir ağı topluluğu sunmaktadır. Önerilen sistem, üç aşamadan oluşmaktadır: ön işleme, derin evrişimsel sinir ağı ve skora dayalı füzyon. Ön işleme aşamasında, panoramik ham görüntüler üzerinde filtreler kullanılarak netleştirme işlemi gerçekleştirilmiştir. Bu sayede görüntüler daha belirgin hale getirilerek önerilen modelin başarımlarının artırılması amaçlanmıştır. Bir sonraki adımda, önceden eğitilmiş derin modele dayalı çok girişli evrişimli sinir ağı modeli tasarlanmıştır. Bu model, diş çürüklerini tespit etmek için özgün bir öğrenme yaklaşımı kullanarak görüntülerdeki önemli özellikleri yakalamaktadır. Son aşamada ise geliştirilen çok girişli ESA modeli, skor düzeyinde birleştirilmektedir. Bu aşamada, her bir girişin çıktısı skorlanmakta ve farklı girişlerin skorları birleştirilerek sonuç elde edilmektedir. Bu sayede, farklı girişlerin bilgileri bir araya getirilerek daha güvenilir bir sonuç elde edilmesi hedeflenmektedir. Önerilen sistemin genel yapısı Şekil 5.2’de gösterilmiştir. Şekil 5.2’de, her bir aşamanın görsel olarak temsil edildiği ve aşamalar arasındaki ilişkinin vurgulandığı bir yapı gösterilmiştir. Ayrıca sistemin genel akışındaki her bir aşama detaylı bir şekilde açıklanmış ve sistemin nasıl işlediği hakkında daha fazla bilgi sunulmuştur.

Mevcut ham görüntülere çeşitli görüntü işleme teknikleri uygulandı. Bu işlem dental görüntülerdeki çürük alanları netleştirmiş ve sınıflandırma performansını artırmıştır. Bu amaçla, panoramik ham görüntüler için sırasıyla keskinleştirme filtresi ve yoğunluk renk haritası uygulandı. Sonuç olarak, aynı boyutta yeni görüntüler elde edildi. Bu işlemin bir örneği Şekil 5.3’te verilmiştir. Şekil 5.3’te görüldüğü gibi ham gri görüntüler için keskinleştirme filtresi $[-1 \ -1 \ -1; -1 \ 9 \ -1; -1 \ -1 \ -1]$. Daha sonra görüntülerin yoğunluk değerleri ayarlanmıştır. Bu sayede yeni görüntünün kontrastı artırılmış oldu. Son olarak filtreleme ve yoğunluk değeri ayarlama işlemleri sonucunda elde edilen son resimlerde çürük bölgesinin keskinleştiği gözlenmiştir.



Şekil 5.2. Önerilen mimarinin yapısı



Şekil 5.3. Önerilen ön işleme aşaması

Bu çalışmada, çok girişli görüntülerin her biri için AlexNet mimarisinin önceden öğrenilmiş ağırlıkları ve bu mimariyi diş çürüğü tespitine uyarlamak için bir transfer öğrenme yaklaşımı kullanılmıştır. Bu süreçte, önceden eğitilmiş AlexNet mimarisinin son üç katmanının yerini yeni tam bağlantılı, Softmax ve sınıflandırma katmanları almıştır. Önerilen modelin genel yapısı ve karakteristik özellikleri Tablo 5.1’de detaylandırılmıştır.

Ek olarak, önerilen model, birden çok ESA mimarisinin softmax çıktı katmanlarında skora (puan) dayalı bir füzyon işlemi kullanmıştır. Önerilen sistemde, her çok girişli görüntü için uygulanan derin ESA mimarilerindeki softmax katmanlarından bir $M \times N$ çıkış matrisi elde edilmektedir [28]. Burada N ve M, sınıf sayısı ve test seti sayısı olarak temsil edilir. Transfer öğrenme yöntemi kullanılan sistemde Denklem 5.1’de verilen yeni skor değeri hesaplanır;

$$\text{skor} = \sum_{i=1}^M \sum_{j=1}^N (A_1(i, j) + A_2(i, j))/2 \quad (5.1)$$

Burada A, ESA tabanlı modeller tarafından oluşturulan skoru temsil eder. Denklem 5.1 kullanılarak $M \times N$ boyutunda yeni bir puan elde edilmiştir. Daha sonra yeni skor değeri kullanılarak her satırın maksimum değerine (M) göre sınıf etiketi belirlenir. Önerilen sistemde, iki giriş görüntüsüne dayalı iki ESA modeli kullanılmıştır. Bu bağlamda, bu yaklaşımın sözde kodu Tablo 5.2’de gösterilmektedir.

Tablo 5.1. Önerilen çok girişli AlexNet mimarisi

	Seviyeler	Adım	Filtre Boyutu/Adım	Çıktı Boyutu
1	Giriş_1	Görüntü	-	227×227×3
2	Evrş1_1	Evrşim	11×11/4	55×55×96
3	Giriş_2	Görüntü	-	227×227×3
4	Evrş1_2	Evrşim	11×11/4	55×55×96
5	Havuz1_1	Maksimum Havuzlama	3×3/2	27×27×96
6	Havuz1_2	Maksimum Havuzlama	3×3/2	27×27×96
7	Evrş2_1	Evrşim	5×5/1	55×55×256
8	Havuz2_1	Maksimum Havuzlama	3×3/2	27×27×256
9	Evrş2_2	Evrşim	5×5/1	55×55×256
10	Havuz2_2	Maksimum Havuzlama	3×3/2	27×27×256
11	Evrş3_1	Evrşim	3×3/2	13×13×512
12	Evrş3_2	Evrşim	3×3/2	13×13×512
13	Evrş4_1	Evrşim	3×3/1	13×13×1024
14	Evrş4_2	Evrşim	3×3/1	13×13×1024
15	Evrş5_1	Evrşim	3×3/1	13×13×512
16	Havuz3_1	Maksimum Havuzlama	3×3/2	6×6×256
17	Evrş5_2	Evrşim	3×3/1	13×13×512
18	Havuz3_2	Maksimum Havuzlama	3×3/2	6×6×256
19	Fc6_1	Tam bağlı katman	-	4096
20	Fc6_2	Tam bağlı katman	-	4096
21	Fc7_1	Tam bağlı katman	-	4096
22	Fc7_2	Tam bağlı katman	-	4096
23	Fc8_1	Tam bağlı katman	-	2
24	Fc8_2	Tam bağlı katman	-	2
25	Softmax_1 / Softmax_2	Softmax	-	2
26	Skor seviyesi	Birleştirme	-	2
27	SÇ	Sınıflandırma Çıkışı	-	-

Tablo 5.2. Önerilen skora dayalı yaklaşımın sözde kodu

```

Giriş: skor1, skor2, YTest
Çıkış: doğruluk
1: for i=1 to M
2:   for j=1 to N
3:     yeni_skor(i,j)=(skor1(i,j)+skor2(i,j))/2
4:   end for j
5: end for i
6: for k=1 to K
7:   if skor(k,1)>=skor(i,2)
8:     YPred(k)=1;
9:   else
10:    YPred(k)=2;
11:   end for k
12: doğruluk=ortalama (YPred==YTest);

```

5.3. Deneysel Çalışmalar ve Sonuçları

Deneysel çalışmalar, NVIDIA Quadro M4000 GPU ve 8GB RAM ile donatılmış bir bilgisayarda gerçekleştirilmiştir. Tüm kodlamalar için MATLAB yazılımı kullanılmıştır. Dış periapikal görüntü veri seti, özel diş kliniklerinde toplanmıştır. Tüm etik sorunlar garanti edilmiştir. Bu çalışmada, diş çürüklerini tespit etmek için yeni bir skora dayalı çok girişli ESA topluluğu (ÇG-DESAT) modeli önerilmiştir. Önerilen modelde çoklu giriş görüntüleri için önceden eğitilmiş AlexNet mimarisinin ağırlıkları kullanılmıştır. Daha sonra ÇG-DESAT modelinin softmax katmanı birleştirilerek sınıf etiketleri belirlenmiştir. ESA mimarisinin eğitimi için deneysel çalışmalarda kullanılan derin parametreler Tablo 5.3'te verilmiştir.

Tablo 5.3. Mevcut çalışmada kullanılan derin ağ parametreleri

Mini-batch boyutu	: 8-16
Maksimum epoch sayısı	: 5-20
Ağırlık azaltma faktörü	: 0.01
İlk öğrenme oranı	: 0.0001
Optimizasyon yöntemi	: SGDM (Momentum ile Stokastik Gradyan İnişi)


Tablo 5.3'te görüldüğü gibi deneysel çalışmalarda epoch sayısı ve batch büyüklüğü sırasıyla 5-20 ve 8-16 değerleri arasında incelenmiştir. Bu ampirik çalışmalarda, %70 eğitim için geri kalanı ise test için kullanılmıştır. Bu rasgele ayırma yalnızca bir kez yapıldı ve tüm deneysel çalışmalarda aynı eğitim/test veri kümeleri kullanıldı. Ayrıca tüm deneysel çalışmaların sonuçları için test prosedürü 100 kez tekrarlanmıştır. Ham görüntülere dayalı AlexNet mimarisi, filtre yaklaşımına dayalı AlexNet mimarisi ve önerilen mimari performansı bu süreçler kullanılarak ayrı ayrı hesaplanmıştır. Bu sonuçlar Tablo 5.4'te verilmiştir.

Tablo 5.4. Deneysel çalışmaları-I sonuçları (%) (transfer öğrenme)

Methot	Minimum	Maksimum	Ortalama	Standart Sapma
AlexNet	86.96	98.26	94.81	1.8309
Filtre-AlexNet	87.83	98.26	94.33	2.0662
Önerilen model	93.04	99.13	96.19	1.5025


AlexNet, Filtre-AlexNet ve önerilen modelden 100 kez çalıştırılarak elde edilen sonuçların minimum, maksimum, ortalama ve standart sapma değerleri Tablo 5.4'te verilmiştir. Bu sonuçlara

göre AlexNet modeli için maksimum doğruluk skoru ham görüntülere ve filtrelenmiş görüntülere dayalı olarak her iki yöntem için de %98.26 olarak gözlemlenmektedir. Tablo 5.4'te görüldüğü gibi, önerilen ÇG-DESAT modeli ile %99.13 doğruluk skoru elde edildi. Ek olarak, duyarlılık, özgüllük, kesinlik ve F1-skoru değerleri gibi diğer performans ölçütleri sırasıyla %98, %100, %100 ve %98,99'dur. Bu doğruluk sonucunun karışıklık matrisi ve ROC diyagramı da Şekil 5.4'te verilmiştir.




Şekil 5.4. Önerilen modelin karışıklık matrisi ve ROC diyagramı

Karışıklık matrisinden de gösterildiği gibi, önerilen model çürüksüz sınıf için %100 ve dış çürüğü tespitinde %98 doğruluk skoru elde etti. Ayrıca önerilen yöntemin eğitim doğruluğu ve kayıp eğrileri Şekil 5.5'te verilmiştir. Şekil 5.5'te görüldüğü gibi eğitim doğruluğu başlangıçta %75 civarında iken, ilk epoch'ta yaklaşık %40 doğruluk skoruna düşmüştür. Bunun ile birlikte ilk epoch aniden %90 doğruluk skoruna yükseldi. Eğitim doğruluk eğrisi, dördüncü aşamadan sonra neredeyse %100 doğruluk skoruna yükseldi. Benzer şekilde, eğitim aşamasının başında kayıp eğrisi 1 civarındaydı ve ilk epoch 3 civarına yükseldi. Dördüncü epochtan sonra kademeli olarak sıfıra inmektedir.



Şekil 5.5. Önerilen modelin artan iterasyon sayılarına karşı eğitim doğruluğu ve kaybı grafikleri

Ek olarak, önerilen modelin yorumlana bilirliliğini sağlamak amacıyla, gradyan ağırlıklı sınıf aktivasyon eşlemesini (Grad-CAM) kullanarak ağın tahminlerini araştırdık. Grad-CAM yöntemi, ağın hangi bölgelerinin tahmini üzerinde en çok etkili olduğunu görselleştirmek için kullanılmaktadır. Bu yöntemi kullanarak çürük görüntüleri için aktivasyon haritalarını oluşturduk ve bu aktivasyon haritası Şekil 5.6’da verilmiştir. Şekil 5.6’da görüldüğü gibi, dört test görüntüsüne ve bu görüntülere karşılık gelen çıktı ısı haritalarına yer verilmiştir. Bu ısı haritalarından, eğitilen derin ESA modelinin verilen diş periapikal görüntülerindeki diş çürüklerini başarılı bir şekilde öğrenebildiği gözlenmektedir. Aktivasyon haritaları, çürük bölgelerinin yoğunluğunu ve önemli bölgelerin vurgusunu göstermektedir. Bu sonuçlar, önerilen modelin çürük tespitinde etkili olduğunu ve belirli bölgelerin çürük varlığını tespit etmek için model tarafından öne çıkarıldığını göstermektedir.



Şekil 5.6. Çürük görüntüsünün aktivasyon haritalarına dayalı örnekler

Önerilen modelde, dış çürüklerini tespit etmek için önceden eğitilmiş bir AlexNet mimarisinin öğrenilmiş ağırlıkları kullanılmıştır. Bu çalışmada, zengin ve çeşitli bir sınıflandırma veri seti kullanılarak eğitilmiş parametreler içeren önceden eğitilmiş derin bir modeli içermektedir [61]. Çalışmadaki amacımız, transfer öğrenme yaklaşımını kullanarak derin bir mimariyi çalışmamıza adapte etmektir. Transfer öğrenme yaklaşımıyla, önceden eğitilmiş bir modelin öğrenilmiş ağırlıkları kullanarak hedef problemimize uyarlanmış bir derin mimari oluşturulmuştur. Ayrıca bu yaklaşımın etkisini değerlendirmek amacıyla, dış çürüklerinin sınıflandırılmasında sıfırdan eğitim modeli de kullanılmıştır. Bu durumda, derin mimarinin ağırlıklarına rastgele başlangıç değerleri verilerek eğitim süreci başlatılmıştır. Yapılan deneysel çalışmalar sonucunda elde edilen doğruluk puanları Tablo 5.5'te verilmiştir.

Tablo 5.5. Deneysel çalışmalar-II sonuçları (%) (sıfırdan eğitim)

Methot	Minimum	Maksimum	Ortalama	Standart sapma
AlexNet	78.26	90.43	86.35	2.9083
Filtre-AlexNet	74.78	90.43	86.25	2.8402
Önerilen model	81.73	92.17	87.57	2.0891

Tablo 5.5'ten görüldüğü gibi, önerilen model %92.17 ile en iyi doğruluk skorunu elde etmiştir. Ek olarak, AlexNet tabanlı ham görüntüler ve AlexNet tabanlı filtrelenmiş görüntüler sırasıyla %86.35 ve %86.25 ortalama doğruluk skoruna ulaştı. Tüm bu sonuçlara göre, transfer öğrenme yaklaşımı temel alınarak önerilen model için kullanılan AlexNet modeli, sıfırdan eğitim yaklaşımına göre yaklaşık %10 daha fazla başarı sağlamıştır. Ayrıca bu performans artışı diğer yöntemlerde de gözlenmiştir. Bu sonuçlardan hareketle, küçük veri seti ile sınıflandırma problemlerinde önceden eğitilmiş derin modellere dayalı eğitilmiş parametrelerin kullanılmasının önemli bir performans artışı sağladığı kanıtlanmıştır.

Literatürde nesne tanıma ve sınıflandırma için geliştirilmiş birçok derin evrişimli sinir ağı modeli bulunmaktadır. Bu mimariler, geniş birçok sınıflı veri kümesi kullanılarak eğitilmiştir. Bu çalışmada, önerilen model önceden eğitilmiş yedi derin modelle karşılaştırıldı: VGG16, VGG19, SqueezeNet, GoogleNet, ResNet18, ShuffleNet Xception, MobileNetv2, DarkNet19 ve Inceptionv3. Bu mimariler ve önerilen model için aynı derin parametreler kullanılmıştır (Tablo 5.3). Ayrıca aynı eğitim/test veri setleri kullanılmış ve bu test verileri için deneysel çalışmalar 100 defa tekrarlanmıştır. Bu sonuçlar için minimum, maksimum, ortalama ve standart sapma değerleri Tablo 5.6'da verilmiştir.

Tablo 5.6. Önceden eğitilmiş derin modellerin sonuçları (%)

Derin Model	Minimum	Maksimum	Ortalama	Standart sapma
VGG16 [29]	74.78	97.39	92.80	3.6473
VGG19 [29]	76.52	96.52	93.27	3.6556
SqueezeNet [30]	54.78	97.39	86.28	9.9827
GoogleNet [31]	88.69	96.52	92.62	1.7499
ResNet18 [32]	66.95	96.52	92.01	3.7495
Xception [33]	70.43	86.95	80.25	3.1831
DarkNet19 [34]	78.26	97.39	93.40	3.0454
MobileNetv2 [35]	90.43	93.91	92	1.0689
Inceptionv3 [36]	87.83	94.78	91.39	2.0269
ShuffleNet [37]	90.43	93.91	92.69	1.1738
Önerilen ÇG-DESAT model	93.04	99.13	96.19	1.5025

Tablo 5.6’da önceden eğitilmiş derin modelin performans sonuçları verilmiştir. Bu sonuçlara göre, derin modeller arasında elde edilen en yüksek ortalama doğruluk skoru %93.40 ile DarkNet19 modeliyle, en kötü ortalama doğruluk skoru ise %80.25 ile Xception modeliyle elde edildi. En yüksek maksimum doğruluk skoru, VGG16, SqueezeNet ve DarkNet19 modelleri kullanılarak %97.39 olmuştur. Tablo 5.6’dan da anlaşılacağı üzere diş çürüğü tespiti için önerilen model, önceden eğitilmiş derin modellere göre daha yüksek performans elde etmiştir.

Diş çürüklerinin tespiti için birçok çalışma yapılmıştır. Bu mevcut çalışmalarda geleneksel makine öğrenmesi ve derin öğrenme yöntemleri kullanılmıştır. Bu yöntemlerin etkinliğini değerlendirmek için çoğunlukla periapikal röntgen görüntüleri kullanılmıştır. Bu görüntüler, diş çürüklerinin tespiti için önceki çalışmada kullanılan veri setlerini test etmek için yaygın bir şekilde kullanılmaktadır. Tablo 5.7’de, daha önceki literatürdeki çalışmalarda kullanılan farklı veri setleri ve bu çalışmalardan elde edilen doğruluk puanları sunulmaktadır. Bu çalışmalar, çeşitli yöntemlerin diş çürüklerinin tespiti için ne kadar başarılı olduğunu göstermektedir. Bu bilgiler, mevcut çalışmaların genel bir bakışını sunarak diş çürüklerinin tespiti konusundaki çeşitli yaklaşımları ve başarı düzeylerini göstermektedir.

Tablo 5.7. Önceki çalışmaların önerilen modelle karşılaştırılması

Kaynaklar	Method	Veri Seti	Sınıf sayısı ve Görüntü	Doğruluk
Geeth ve ark. [14]	İstatistiksel özellik çıkarma ve geri yayımlı sinir ağı	Periapikal görüntü	2 sınıf ve 105 görüntü	%97.1
Prajapati ve ark. [15]	VGG16 (ince ayar)	Periapikal görüntü	3 sınıf ve 251 görüntü	%87.5
Singh ve ark. [16]	RT - DCT- PCA ve rastgele orman sınıflandırıcısı	Panoramik görüntü	2 sınıf ve 93 görüntü	%86
Son ve ark. [20]	Yarı denetimli bulanık kümeleme ve graf tabanlı kümeleme algoritması	Ağız içi ve Panoramik görüntü	5 sınıf ve 87 görüntü	%92.74
Lee ve ark. [23]	GoogleNet ve Inception v3	Periapikal görüntü	2 sınıf ve 3000 görüntü	%89
Leo ve Reddy [24]	Yapay sinir ağları ve derin sinir ağları	Periapikal görüntü	4 sınıf ve 480 görüntü	%96
Bui ve ark. [26]	Derin özellikler ve DVM	Periapikal görüntü	2 sınıf ve 533 görüntü	%91.7
Majanga ve Viriri [27]	Morfolojik yöntemler ve derin özellikler	Periapikal görüntü	2 sınıf ve 11,147 görüntü	%97
Vinayahalingam ve ark. [28]	MobileNet V2	Periapikal görüntü	2 sınıf ve 500 görüntü	%87
Önerilen Model	Skora dayalı çok girişli ESA topluluğu	Periapikal görüntü	2 sınıf ve 340 görüntü	%99.13


Tablo 5.7’den görüldüğü gibi, önerilen model, diş çürüğü tespiti için karşılaştırılan mevcut çalışmalardan daha iyi bir doğruluk puanı üretti. Geetha ve arkadaşları [14] daha önceki çalışmalarda %97.1 ile en iyi doğruluk skorunu elde ederken, Singh ve Sehgal [16] %86 ile en kötü doğruluk skorunu vermiştir. Ayrıca, mevcut çalışmalar ortalama %90’lık bir doğruluk skoru üretmiştir. Bu çalışmaların sonuçları, önerilen yöntemin bu alanda değerli bir katkı sağladığını ve mevcut yöntemlerle karşılaştırıldığında daha yüksek doğruluk puanlarına ulaştığını göstermektedir. Sonuç olarak mevcut çalışma, önceki araştırmalara göre diş çürüğü tespiti için yapılmış en kapsamlı deneysel çalışmalardan biridir. Ayrıca, önerilen model %100’e yakın doğruluk performansına sahip, gerçek zamanlı bilgisayar destekli sistemlerde diş hekimlerine yardımcı olabilir.

6. KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE RESNET VE SWIN TRANSFORMATÖR TABANLI UNET MİMARİSİNE DAYALI MAKSİLLER SİNÜS TESPİTİ UYGULAMASI

Uzmanlarının en uygun tedavi seçeneklerini belirlemek için maksiller sinüs sınırlarını doğru bir şekilde bilmeleri ve dişlerle ilgili durumu radyografilerde netleştirmeleri gerekir. Bu çalışmada, Konik Işınli Bilgisayarlı Tomografi (KIBT) görüntülerinde maksiller sinüs enfeksiyonlarının saptanmasını kolaylaştırmak ve cerrahi müdahalelerde hekim hatalarını en aza indirmek amaçlanmıştır. Mevcut çalışmada, KIBT görüntülerinde maksiller sinüs ile ilişkili patolojik durumların ve enfeksiyonların sınırlarını belirlemek için ResNet ve swin transformatör tabanlı yeni bir UNet yapısı önerilmiştir. Maksiller sinüs teşhisi için kendi kendine dikkat mekanizmasını kullanan en son teknoloji swin transformatör modeline dayalı yeni bir yaklaşımdır. Önerilen ağ mimarisinin kodlayıcı kısmında ResNet mimarisi kullanılırken, kod çözücü kısmında swin transformatör blokları ile yeni bir yapı oluşturulmuştur. ResNet mimarisi ile güçlü başlangıç özellikleri sağlanırken, swin transformatör bloğu ile de verimli küresel bağlam özellikleri (long-range contextual information) üretilmiştir.

6.1. Veri Seti

Bu çalışmada kullanılan veri seti özel diş kliniklerinden elde edilen görüntüler ile oluşturulmuştur. Tüm görüntüler bir I-CAT Vision sistemi (Imaging Sciences International, Hatfield, PA, ABD) kullanılarak elde edildi. Tarama parametreleri şu şekildeydi: 120 kVp, 5 mA, 8,9 sn çekim süresi, 0,3 mm kalınlığında eksenel dilim ve izotropik vokselle boyutu ve 16×13 cm görüntü alanı. Tüm görüntüler Tıpta Dijital Görüntüleme ve İletişim formatında kaydedildi. Tüm veriler, tek DICOM dosyaları olarak 0,3 mm kalınlığındaki eksenel dilimlerden oluşturulmuştur. Eksenel görüntüler, DICOM dosyası başına tek bir kare olarak 512×512 matrisle dışa aktarılmıştır. Bu veri setinde 315 hastanın KIBT görüntüleri analiz edildi. Bulanık veya kırık kist ve enfeksiyon görüntüleri dahil olmak üzere toplam 17 hastanın KIBT görüntüleri hariç tutuldu. Sonuç olarak 298 hastanın KIBT görüntüleri çalışmaya dahil edilmiştir. Şekil 6.1, veri setinden elde edilen maksiller KIBT görüntülerinin bazı örneklerini göstermektedir. Maske etiketlemesi uzman diş hekimi kontrolünde yapılmıştır.




Şekil 6.1. Bu çalışmada kullanılan bazı KIBT görüntü örnekleri

6.2. Önerilen Yöntem


Cao ve arkadaşları [109], swin transformatörden esinlenerek Swin-UNet mimarisini geliştirmişlerdir. Bu yeni model, büyük veri kümelerinde test edilmiş ve etkinliği kanıtlanmıştır. Önceki ESA tabanlı yöntemlere kıyasla, dönüştürücüler daha yüksek performans göstermiştir, ancak bu performans artışı genellikle büyük veri kümelerine dayanmaktadır [109,138]. Bununla birlikte, diş hastalıkları için kullanılan veri kümeleri genellikle sınırlı örnek sayısına sahiptir. Bu nedenle, oluşturduğumuz özgün veri seti ile gerçekleştirdiğimiz deneysel çalışmalarda Swin-UNet modelinin, maksiller sinüs tespiti için düşük hata sonuçları ürettiğini gözlemledik. Yukarıdaki problemi temel alan bu uygulamada, piksel düzeyinde maksiller sinüs tespiti için “önceden eğitilmiş ResNet mimarisi” ve “swin transformatör tabanlı kod çözücü” temelli yeni bir ağ mimarisi önerilmiştir. Bu yeni ağ mimarisi ResNet tabanlı kodlayıcı, darboğaz ve swin transformatör tabanlı kod çözücü yapılarından oluşmaktadır. Kodlayıcıda ResNet modülü ile omurga ağından düşük seviyeli ve yüksek seviyeli özellik haritaları elde edilmiştir. Kod çözücü kısmı, geleneksel evrişim katmanları yerine bir Swin transformatörü ve parça genişletme bloklarından oluşuyordu. Swin transformatör çıkışında elde edilen özellik haritalarının boyutunu artırmak için parça genişletme katmanı kullanıldı. Önerilen Res-Swin-UNet yapısı Şekil 6.2’de gösterilmektedir.

Önerilen Res-Swin-UNet ağının kodlayıcı modülünde ResNet ağ mimarisi kullanılmıştır. Şekil 6.3 (a)’da ResNet50 ve ResNet101 ağ mimarilerinin katman yapılarını, Şekil 6.3 (b)’de ise katmanlar içerisindeki blok yapıları gösterilmiştir. Şekil 6.3 (a)’da gösterildiği gibi, önerilen model ResNet ağ mimarisinden beş farklı özellik haritası alınmıştır. İlk dört seviyenin özellik haritaları ara bağlantılarla kodlayıcı ünitesine aktarılırken, son seviyenin özellik haritası, giriş özellik haritasına swin transformatörün iki kez uygulandığı darboğaz (bottleneck) bloğuna aktarılmıştır.

Daha sonra giriş özelliği haritası kod çözücü birimine girildi. Kodlayıcı üzerinde ResNet18, ResNet34, ResNet50 ve ResNet101 ağ mimarilerinin kullanıldığı deneysel çalışmalar, ResNet101 ve ResNet50 mimarilerinin en iyi sonuçları verdiğini ortaya koydu.



Şekil 6.2. Res-Swin-UNet Mimarisinin yapısı



Şekil 6.3. (a) Resnet50 ve Resnet101 mimarileri ve (b) katman blok yapıları

Önerilen Res-Swin-UNet ağının kod çözücü modülü de kodlayıcı birimine benzer şekilde dört seviyeden oluşmaktadır. Her seviye bir parça genişletme katmanı ve iki swin transformatör katmanı içermektedir. Darboğaz katmanının çıktısı, kod çözücü modülünün birinci düzeyine girdi olarak kullanıldı. Ardından parça genişletme katmanı, elde edilen özellik haritasının boyutunu artırdı. Yeniden boyutlandırılan özellik haritası, ara bağlantılar kullanılarak kodlayıcıdaki özellik haritalarıyla birleştirildi. Son katmandaki seviyede çıktı ilk üç seviyesindeki birleştirilmiş özellik haritalarına swin transformatör bloğunun iki kez uygulanmasıyla elde edildi. Kod çözücünün son seviyesinde swin transformatör katmanı yerine evrişim katmanı kullanılarak nihai öznitelik haritası elde edilmiştir. Kod çözücüde, son seviye giriş özelliği haritası 4096×128 boyutundaydı. Özellik haritasının boyutu parça genişletme katmanı ile artırıldı ve yeniden boyutlandırma katmanı ile $256 \times 256 \times 32$ olarak yeniden boyutlandırıldı. Yeniden boyutlandırılan özellik haritasına 32 filtre evrişimi, toplu normalleştirme ve ReLU katmanları uygulanmıştır. Böylece $256 \times 256 \times 32$ boyutlarında son özellik haritası oluşturulmuştur. Tahmin haritası, kod çözücünün son katmanında ardışık bir evrişim ve sigmoid aktivasyon fonksiyonu ile elde edilmiştir. Önerilen modelin katman detayları Tablo 6.1’de gösterilmektedir. Tablo 6.1’de patch: dönüştürücü için girdinin parça sayısı, head: dönüştürücüdeki kullanılan dikkat başlık sayısı, ws: swin transformatördeki dikkat penceresinin boyutu, mlp: transformatör içindeki MLP nöron sayısı olarak tanımlanmaktadır.

Tablo 6.1. Res-Swin-UNet ağının katman ve parametre ayarları

Modül	Detaylar	
Kodlayıcı	ResNet	
Dar boğaz	Swin-Transformatör $\times 2$	Patch:36, Head:8, ws:4, mlp:512, gömme:1024
Kod Çözücü Aşaması 1	Parça Genişletme Adım=2	Patch:36, Head:8, ws:4, mlp:512, gömme:512
	Swin-Transformatör $\times 2$	
Kod Çözücü Aşaması 2	Parça Genişletme Adım=2	Patch:144, Head:8, ws:16, mlp: 512, gömme:256
	Swin-Transformatör $\times 2$	
Kod Çözücü Aşaması 3	Parça Genişletme Adım=2	Patch:576, Head:4, ws:16 mlp: 512, gömme:128
	Swin-Transformatör $\times 2$	
Kod Çözücü Aşaması 4	Parça Genişletme Adım=4	
	Evrişim+BN+ReLU	filtre boyutu=32, çekirdek boyutu:3 $\times$ 3, adım:1
	Evrişim	filtre boyutu =1, çekirdek boyutu:3 $\times$ 3, adım:1

6.3. Deneysel Çalışmalar ve Sonuçları

Mevcut çalışma, maksiller sinüs ile ilgili enfeksiyonları ve patolojileri saptamak için ResNet ve Swin transformatör tabanlı UNet'ten oluşan yeni bir yaklaşım önerdi. Önerilen Res-Swin-UNet mimarisi, 315 hastadan toplanan bir tomografi görüntü veri setine uygulandı. Önerilen modelin performansını daha iyi değerlendirmek için, karşılaştırma amacıyla UNet [110], PSPNet [139], LinkNet [140] ve Özellik Piramit Ağları (FPNet) [141] gibi çeşitli son teknoloji yaklaşımlar kullanılmıştır.


Tüm deneysel çalışmalar i7-10875H işlemci, 32 GB ram ve 11 GB-RTX 2080 GPU ile donatılmış bir bilgisayarda gerçekleştirilmiştir. Bilgisayarda kurulu olan işletim sistemi Windows'tur. Önerilen ağ modeli eğitiminde epoch sayısı 100, mini-batch boyutu 16 olarak sabitlenmiştir. Uygulamada verimli bir öğrenme oranı tahmini için Keras kütüphanesinde bulunan ReduceLROnPlateau modeli kullanılmıştır. Model, öğrenme oranı değerini belirlemek için kayıp değerini kontrol etti. Az sayıda hastada kayıp değerinin düşmemesi ihtimaline karşı öğrenme oranını azaltmak için öğrenme oranı bir faktör değeri ile çarpıldı. Bu nedenle, yeni öğrenme oranı hesaplaması, $lr_new = lr_old * faktör$; burada lr_old , önceki öğrenme oranı ve lr_new , yeni öğrenme oranıdır. Deneylerde faktör değeri 0,1 (faktör=0,1) olarak atanmış ve hasta değeri 8 olarak belirlenmiştir. Başlangıç öğrenme oranı 0,001, olası minimum öğrenme oranı değeri ise 0,00001 olmuştur. Eğitim, Adam optimizasyon ile gerçekleştirildi. Elde edilen bölütlemeleri değerlendirmek için F1-skoru, ortalama birleşim üzerinde kesişme oranı (mIoU) ve Eğri Altındaki Alan (AUC) metrikleri dikkate alındı.

Tablo 6.2, swin transformatör tabanlı dört UNet modeli, Swin-UNet-ResNet18, Swin-UNet-ResNet34, Swin-UNet-ResNet50 ve Swin-UNet-ResNet101 için değerlendirme ölçümlerini göstermektedir. Tablo 6.2'de görüldüğü gibi, Swin-UNet-ResNet50 ve Swin-UNet-ResNet101 modelleri aynı skorlarla (%99.87) en yüksek doğruluğu üretti. İkinci en yüksek doğruluk skoru Swin-UNet-ResNet34 (%99.86) ve en düşük doğruluk skoru Swin-UNet-ResNet18 (%99.85) olmuştur. Önerilen modellerde, daha derin ağ modelleri (101 ve 50 katmanlı) diğer modellere göre daha iyi doğruluk skorları üretmiştir. Ayrıca, daha derin ağ modelleri, IoU, F1 skoru, kesinlik ve duyarlılık metriklerine dayalı olarak diğer iki derin modelden daha yüksek skorları vermiştir. Şaşırtıcı bir şekilde, AUC metriğine göre Swin-UNet-ResNet34 modeli önerilen tüm modeller arasında en yüksek AUC performans skoru (%99.36) üretti.









Tablo 6.2. Önerilen modellerin performansı (%)

Önerilen model	IoU	F1-skoru	Kesinlik	Duyarlılık	Doğruluk	AUC
Swin-Unet-ResNet18	81.42	89.76	93.06	86.68	99.85	98.79
Swin-Unet-ResNet34	83.33	90.90	89.76	92.08	99.86	99.36
Swin-Unet-ResNet50	84.14	91.39	91.20	91.58	99.87	98.92
Swin-Unet-ResNet101	84.71	91.72	91.57	91.87	99.87	99.18

Şekil 6.4, önerilen her modelde yanlış pozitif oranı ile gerçek pozitif oranını ve duyarlılık ile kesinlik eğrilerini göstermektedir. Şekil 6.4'te görüldüğü gibi, her model için AUC değerleri 0.98'in üzerindeydi. ResNet34 ve ResNet101 modelleri sırasıyla 0.9936 ve 0.9918 AUC değerleri üretti. Ayrıca F1 skoru değerleri 0.89'un üzerindeydi. ResNet101 ve ResNet50 modelleri, sırasıyla 0.9172 ve 0.9139 F1-skoru üretmiştir.

**Şekil 6.4.** Önerilen her bir yöntem için yanlış pozitif oranı ile gerçek pozitif oranı ve duyarlılık ile kesinlik eğrileri

Şekil 6.5, önerilen modellerin örnek temel gerçeklerini ve bölütleme sonuçlarını göstermektedir. Şekil 6.5'in birinci ve ikinci sütunları, orijinal görüntüleri ve maske bölütlemelerini göstermektedir. 3'ten 6'ya kadar olan sütunlar sırasıyla önerilen Swin-MFNet tabanlı ResNet18, ResNet34, Resnet50 ve ResNet101 ağlarını göstermektedir. Şekil 6.5'te, maske (etiket) bölütlemeleriyle karşılaştırıldığında, birinci, beşinci, altıncı, sekizinci ve onuncu satırlarda önerilen tüm yaklaşımların elde ettiği bölütlemeler neredeyse aynıydı. Ayrıca, diğer görüntüler için üretilen bölütlemelerde alt ve üst bölütlemeler bulunuyordu. Genel olarak, elde edilen bölütlemeler makul ve görsel olarak değerlendirilmeye değerdi.

	Görüntü	Maske	ResNet18	ResNet34	ResNet50	ResNet101
img-1			iou:88.4	iou:88.47	iou:91.41	iou:90.58
img-2			iou:69.3	iou:60.28	iou:66.14	iou:75.78
img-3			iou:81.18	iou:82.53	iou:84.51	iou:88.06
img-4			iou:77.54	iou:78.23	iou:78.16	iou:78.34
img-5			iou:68.47	iou:90.45	iou:88.56	iou:89.61
img-6			iou:87.08	iou:85.58	iou:86.36	iou:88.07
img-7			iou:57.87	iou:61.56	iou:61.25	iou:65.3
img-8			iou:80.2	iou:83.23	iou:87.86	iou:87.52
img-9			iou:56.72	iou:68.62	iou:75.19	iou:69.92
img-10			iou:77.62	iou:83.01	iou:83.57	iou:86.06

Şekil 6.5. Önerilen modellerin görsel sonuçları

Ayrıca önerilen Res-Swin-UNet modeli literatürdeki mevcut çalışmalar ve geliştirilen modeller ile karşılaştırılmıştır. Res-Swin-UNet modelinin performansı, maksiller sinüs ile ilgili enfeksiyonları ve patolojileri tespit etmede önceki çalışmalarla karşılaştırıldı. Tablo 6.3'te literatürdeki çalışmalar ile önerilen yöntemden elde edilen başarımlar sonuçları gösterilmektedir. Sadece bir çalışma [29] sinüsü yerel olarak bulurken, diğer çalışmalar maksiller sinüsü sınıflandırmaya çalıştı. Bu sonuçlara göre, önceki araştırma projelerinin ortalama doğruluk skoru %90 civarındadır. Bu güncel ayrıntılı araştırma, en son teknolojiye dayalı bir model geliştirilerek yaklaşık %99 doğruluk skoru elde etmiştir.

Ancak, önerilen modelin performansını farklı veri kümeleri kullanan önceki çalışmalarla karşılaştırmak uygun değildir.


Tablo 6.3. Önerilen modelin önceki çalışmalar ile karşılaştırılması

Referans	Metot	Sınıf ve görüntü sayısı	Doğruluk
Jung ve ark. [29]	3D nnU-Net derin model	hava ve lezyon maksiller sinüs 83 görüntü	%90
Mori ve ark. [30]	Derin transfer öğrenme yaklaşımı	sağlıklı ve iltihaplı maksiller sinüs 470 (T50) görüntü	%93.1
Murata ve ark. [31]	Alex-Net derin model	sağlıklı ve iltihaplı maksiller sinüs 6000 görüntü	%87.5
Kim ve ark. [32]	VGG-16 VGG-19 ve ResNet-101 çoklu derin öğrenme modelleri	sağlıklı ve maksiller sinüs 4860 görüntü	%94.1
Kuwana ve ark. [33]	DetectNet derin model	sağlıklı, iltihaplı ve kist maksiller sinüs 1174 görüntü	%91
Kim ve ark. [34]	Artık Blok-Net derin model	sağlıklı ve maksiller sinüs 9000 görüntü	%93
Ohashi ve ark. [35]	Bilgisayar destekli algılama sistemi	sağlıklı ve maksiller sinüs 98 görüntü	%73.5
Önerilen Model	Res-Swin-UNet	maksiller sinüs 298 images	%$\geq$99

Bu tez çalışmasında, önerilen modelin en gelişmiş yöntemlerle kapsamlı karşılaştırmalarını yapmıştır. Bu amaçla Swin-UNet [109], Attention-UNet [114], UNet [110], PSPNet [139], LinkNet [140] ve FPN [141] yaklaşımları kullanılmıştır. Sonuçlar, IoU ve F1-skoru değerlerine göre değerlendirildi ve ardından Tablo 6.4'te tanıtıldı. IoU performans skorlarına göre, FPN yaklaşımı, önerilen çalışmadan sonra en yüksek olan 81.52 değerindeki skoru üretti. LinkNet ve UNet yöntemleri sırasıyla 77.77 ve 79.24 IoU skorları verdi. Swin-UNet ve Attention-UNet modelleri sırasıyla 46.64 ve 47.29 IoU skorları üreterek diğer yaklaşımlardan daha düşük değerler verdi. Önerilen yöntem en yüksek IoU skorunu vermiştir. Önerilen Res-Swin-UNet-Res50 modelinde 84.14 IoU performans skoru gözlemlenirken, Res-Swin-UNet-Res101 modelinde 84.71 IoU performans skoru gözlemlenmiştir.

Tablo 6.4. Önerilen modelin performanslarının (%) güncel yöntemlerle karşılaştırılması

Model		IoU	F1-skoru
Swin-UNet		46.64	63.61
Attention-UNet		47.29	64.22
UNet		79.24	88.42
FPNet		81.52	89.82
LinkNet		77.77	87.49
Önerilen Res-Swin-UNet	ResNet50	84.14	91.39
	ResNet101	84.71	91.72



Şekil 6.6. Önerilen modellerin görsel bölütlemesinin son teknoloji yöntemlerle karşılaştırılması

Şekil 6.6, önerilen ve son teknoloji yöntemlerin görsel bölütleme sonuçlarını göstermektedir. Şekil 6.6'nın birinci ve ikinci sütunları orijinal görüntüleri ve maske (etiket) bölütlemesini gösterirken, 3 ila 7 arasındaki kolonlar Swin-UNet, Att-UNet, UNet, FPN ve LinkNet yaklaşımları tarafından üretilen görsel bölütleme sonuçlarını gösterir. Son olarak, sütunun 8. ve 9. bölümünde, önerilen Res-Swin-UNet tabanlı ResNet50 ve ResNet101 ağlarının görsel sonuçlarını göstermektedir. Şekil 6.6'da görüldüğü gibi, UNet, FPN ve LinkNet yaklaşımlarının görsel bölütlemesi, Swin UNet ve Att-UNet modellerinden daha iyiydi. Bu görsel bölütleme aynı zamanda yüksek IoU ve F1-skoruyla da kanıtlamaktadır. Görsel olarak, önerilen yöntemlerin bölütleme bölütlemesi, maske bölütlemesi dikkate alındığında oldukça sağlamdı. Önerilen yöntemler, etiketlenen gerçek bölümlere çok benzeyen bölütleme sonuçları üretmiştir.



7. PANORAMİK DİŞ RÖNTGEN GÖRÜNTÜLERİNDE ARTIK BLOKLAR, DEĞİŞTİRİLMİŞ TERS ARTIK BLOK, BCONVLSTM'YE DAYALI GÖMÜLÜ DİŞ TESPİTİ UYGULAMASI

Gömülü dişler her yaşta görülebilen, ilerleyen aşamalarda diş çürümesine, kök rezorbsiyonuna ve ağrıya neden olan yaygın bir sorundur. Son yıllarda, derin ESA tabanlı ağlar kullanılarak tıbbi görüntü bölütlemesinde büyük ilerlemeler kaydedilmektedir. Bu bölümde panoramik diş görüntülerinden, gömülü dişlerin otomatik olarak tanımlanmasına yönelik bir uygulama öneriyoruz. Mevcut ağlar arasında medikal görüntü bölütlemesinde U-Net mimarileri yaygın olarak uygulanmaktadır. Bu uygulamada diş röntgenlerinde görüntü bölütlemesi için, modifiye edilmiş ters çevrilmiş artık blokların (inverted residual block, MobileNetV2) kullanıldığı bloklar ile U-Net'in ağ kapasitesi yoğun bağlantılardan yararlanarak yükseltilmektedir. Aynı zamanda atlama bağlantısında basit bir birleştirme yerine Çift Yönlü Evrişimsel Uzun Kısa Süreli Belleğin (BConvLSTM) kullanıldığı bir yöntem önerilmektedir.


7.1. Veri Seti

Veri seti 304 adet gömülü dişleri içeren panoramik görüntülerden oluşmaktadır. Özel diş kliniklerinde toparlanan panoramik görüntüler, uzman bir diş hekimi yardımı ile etiketleme işlemi gerçekleştirilmiştir. Şekil 7.1'de, veri setinden elde edilen panoramik diş görüntülerindeki gömülü diş ile ilgili bazı örnekler gösterilmektedir. Birinci sütun panoramik diş görüntüleri, ikinci sütunda ise görüntüye karşılık maskelerine yer verilmiştir.

7.2. Önerilen Yöntem

Panoramik diş röntgen görüntülerine sırasıyla gri dönüştürme ve veri artırma işlemi uygulanmıştır. Veri artırma, mevcut veri kümesini çeşitli dönüşümler, değişiklikler veya manipülasyonlarla genişletme işlemidir. Bu işlem, veri çeşitliliğini ve genellemeyi artırır. Derin öğrenme modelleri, daha fazla varyasyona maruz kalan veriyle eğitildiğinde, daha iyi genelleme yapabilir ve daha çeşitli girdi görüntülerini tanıyabilmektedir. Bu yüzden bu uygulamada gömülü diş içeren panoramik radyografi görüntülerinden oluşan veri setine artırma teknikleri uygulanmıştır. Python kütüphanelerinden biri olan ve çeşitli artırma tekniklerini içeren "Albumentation" kullanılmıştır [142]. Merkezi kırpma, rastgele kırpma, rastgele döndürme (90^0), ızgara distorsiyonu, yatay çevirme ve dikey döndürme yöntemleri olmak üzere toplam altı yöntem kullanılmıştır. Bu işlemler sonucunda orijinal görüntülerle birlikte toplam 2128 adet görüntü elde

edilmiştir. Şekil 7.2, orijinal görüntüye uygulanan yöntemler sonucunda oluşan görüntü ve maskeyi sıralı olarak göstermektedir.



Şekil 7.1 Veri setindeki bazı panoramik diş görüntüsü ve maskesi



Şekil 7.2. Gömülü diş röntgen görüntüsü ve veri arttırma


Elde edilen 256×256 boyutundaki gri görüntü, önerilen bölütleme modelinin girdisi olarak kullanılmıştır. Gömülü diş tespiti için, U-Net mimarisine dayalı ResMIBCU-Net adlı bir bölütleme mimarisi önerilmiştir. Önerilen modelde ilk olarak daha iyi özellik birikimine odaklanmak için kodlayıcı bölümünde artık bloklar, değiştirilmiş ters çevrilmiş artık blok ve son olarak “conv block” olarak adlandırılan bir katman kullanılarak genişletilmiş bir artık ağ öneriyoruz.

Önerilen modelde orijinal U-Net ağındaki standart evrişim işlemlerinin yanı sıra Denklem 7.1 ve Denklem 7.2’de verilen MobileNetV2’deki blok yapısının değiştirilmiş bir versiyonu kullanılmıştır. Bu yapı değiştirilmiş ters çevrilmiş artık blok yapısı (modified inverted residual block) olarak adlandırılmıştır.

$$x_1 = s(w_1 x + b_1) \quad (7.1)$$

$$y = F_{(x)} \odot x_1 \quad (7.2)$$


Burada x_1 giriş özellik haritasına uygulanan 1×1 evrişim katmanı ve ardından uygulanan sigmoid (s) aktivasyon fonksiyonunun çıktısıdır. $F_{(x)}$, MobileNetV2 de kullanılan katmanlardan farklı olarak 3×3 ve 7×7 ’lik boyutlarda evrişim katmanlarının kullanıldığı bir işlem içermektedir. $F_{(x)}$ 2 katmandan oluşan ara katmanları temsil etmektedir. Birinci katman 3×3 ve 7×7 ’lik boyutlarda evrişim işlemin çıktılarının element bazında ekleme işleminin gerçekleştiği evrişim bloğudur. İkinci katman ise derinlemesine evrişim özellik haritasına 1×1 ’lik noktasal evrişim ve sigmoid aktivasyon işlemidir. Eşitlik 6’da da belirtildiği üzere $F_{(x)}$ ve x_1 katmanının çıkışı element bazında çarpma ($\odot$) işlemine tabi tutulur. Son olarak y ise çıktı özellik katmanını ifade etmektedir. Şekil 7.3 (a) MobileNetV2 yapısını, Şekil 7.3 (b) ise değiştirilmiş ters çevrilmiş artık blok yapısı gösterilmiştir. Önerilen bu artık blok yapıları sayesinde sinir ağının alt katmanlarındaki görüş alanını artırarak hassas düşük seviyeli özellikleri çıkarmaları sağlanmaktadır. Kodlayıcı/kod çözücü arasındaki atlama bağlantıları, ön plan nesnelerin ince ayrıntıları doğru tespit edilmesi için yardımcı olmaktadır [143].



Şekil 7.3. (a) MobileNetV2’nin genel yapısı (b) Değiştirilmiş ters çevrilmiş artık blok

İkinci adımda ise kod çözücü modülünün farklı bloklardan çıkarılan özelliklerin birleştirildiği, BConvLSTM ve conv block katmanının kullanıldığı verimli bir omurga ve geliştirilmiş atlama yolları önermekteyiz. Kodlayıcı bölümünde mimari 5 ayrı bloktan oluşmaktadır. Bu bölümde temel U-Net mimarisindeki düz evrişim blokları kaldırılarak artık evrişim birimleri ile yer değiştirildi. İlk 4 bloktaki her adım 3×3 'lük bir evrişim, BN ve ReLU aktivasyon fonksiyonu içermektedir. Ayrıca bloklar arası geçişlerde 2×2 'lik maksimum havuzlama katmanı kullanılmıştır. Buna ek olarak bloklar içerisinde yer alan belirli evrişim katmanlarından oluşan özellik haritalarının, son katmanda oluşan özellik haritasıyla birleştirildiği artık blok yapısı bulunmaktadır. Artık blok yapısı ağdaki yapılarda kendinden önceki katmanlardaki özelliklerden yararlanmasını ve kaybolan gradyan riskinden kaçınmasını istemektedir. Önerilen ağ mimarisinde artık bağlantılı bir model kullanılmakta ve bununla birlikte özellik haritalarının sayısı her blokta ikiye katlanarak gitmektedir. Ağdaki bu evrişim işlemleri ile farklı türdeki özelliklerin öğrenilmesine yardımcı olmaktadır. Ayrıca kodlayıcıdan gelen öznitelik haritaları, kod çözücünün öznitelik haritalarından daha düşük seviyededir, bu anlamsal farka anlamsal boşluk denir [143]. Kodlayıcı yolundaki maksimum havuzlama katman çıktıları, yüksek özellik haritaları elde edilmesi için değiştirilmiş ters çevrilmiş artık blok mimarisine girdi olarak kullanılmıştır. Bu yoğun atlama bağlantıları, birleştirme öncesinde kodlayıcı ve kod çözücü özellikleri arasındaki anlamsal boşluğu azaltmaktadır. Son olarak kodlayıcı çıkışı conv block olarak adlandırılan bir dar boğazdan geçirilerek özellik haritalarının etkinliği artırılmıştır. Conv block hem son katmanda kodlayıcı/kod çözücü arasında köprü görevi görmektedir hem de kodlayıcı kısmında atlama omurgasının son katmanı olarak görev yapmaktadır. Conv block olarak adlandırılan artık yapı Şekil 7.4'te gösterilmiştir.

Kod çözücü bölümü ResBCU-Net [74]'ten esinlenen BConvLSTM içeren bir omurga kullanılmıştır. Kodlayıcı bölümünden elde edilen özellik haritaları Şekil 7.4'te gösterildiği gibi BConvLSTM'ye girdi olarak uygulanmıştır. Her blokta BConvLSTM çıktıları modifiye edilmiş ters çevrilmiş artık blok öznitelikleri ile birleştirilip (concatenate) conv block işleminden geçirilen yoğun bağlantılı bir atlama katmanı oluşturulmuştur. Yukarı örnekleme işlevi ile kod çözücünün bir üst adımı gerçekleşmektedir. Kod çözme yolunun sonunda conv block evrişim çıktıları, 1×1 'lik bir evrişim ve sigmoid aktivasyon işlevine tabi tutulmuştur. Oluşan tahmin haritası piksel tabanlı olarak sınıflandırılır. Tahmin haritasındaki 1 piksel değeri gömülü dış bölgesinin olduğunu, 0 piksel değeri normal bir bölge olduğunu göstermektedir. Önerilen ResMIBCU-Net yapısı Şekil 7.4'te verilmiştir.




Şekil 7.4. ResMBCU-Net mimarisinin yapısı

7.3. Deneysel Çalışmalar ve Sonuçları

Python'da geliştirilen tüm deneyleri gerçekleştirmek için Google ortak colaboratory platformu kullanıldı. Ağın eğitimi sırasında, oluşturulan derin bölütleme mimarisi ResMBCU-Net'in parametreleri manuel olarak belirlendi. Sonuç olarak, maksimum epoch boyutu 100'e ve mini batch boyutu 8'e ayarlandı. 0.001 öğrenme oranıyla, eğitim optimizasyonu için "Adam" yaklaşımı kullanıldı. Uygulamada verimli bir öğrenme oranı tahmini için Keras kütüphanesinde bulunan ReduceLROnPlateau modeli kullanılmıştır. İlk öğrenme oranı 0,001 olarak ayarlandı ve doğrulama kaybı 10 epochtan sonra azalmadıysa, ReduceLROnPlateau kullanılarak öğrenme oranının 0,0001'e düşmesine izin verildi. Veri setinde 2128 X-ray görüntüsü bulunduğu ve rastgele seçilen veri setinin %70'i eğitimde, %15'i doğrulama için ve geri kalan %15 veri seti ise geliştirilen derin bölütleme ağının test edilmesinde kullanılmıştır. Böylece eğitim, doğrulama ve test setlerinde sırasıyla 1489, 320 ve 319 panoramik görüntü içermektedir.

Geliştirilen derin bölütleme ağının eğitim eğrileri Şekil 7.5'te gösterilmektedir. Şekil 7.5 (a) eğitim (mavi renk, training) ve doğrulama (turuncu renk, validation) doğruluk eğrilerini gösterirken, Şekil 7.5 (b) sırasıyla eğitim ve doğrulama setleri için kayıp eğrilerini göstermektedir.



Şekil 7.5. Modellerin eğitim görselleştirmesi; (a) doğruluk eğrisi, (b) kayıp eğrisi


Şekil 7.5 (a)'da görüldüğü gibi, eğitim doğruluğu başlangıçtaki birkaç epochta %90'ın üzerine çıktı ve benzer şekilde Şekil 7.5 (b)'de görüldüğü gibi eğitim kaybı değeri birkaç epochtan sonra 0,2 değerinin altına düşmüştür.

Tablo 7.1'de önerilen yöntem için performans değerlendirme ölçütleri verilmiştir. Tablo 7.1'de görüldüğü gibi, %91.59 F1-skoru, %84.48 IoU, %90.71 duyarlılık ve %99.82 doğruluk skorları elde edildi.

Tablo 7.1. Test seti için performans değerlendirme ölçütleri


Model	F1-skoru	IoU	Duyarlılık	Doğruluk
ResMIBCU-Net	0.9159	0.8448	0.9071	0.9982

Şekil 7.6'da, ROC eğrisi gösterilmiştir. ROC eğrisi çiziminde, x eksenı yanlış pozitif oranı gösterirken, y eksenı doğru pozitif oranı gösterir. Şekil 7.6'da görüldüğü gibi, yanlış pozitif oranı 0.0 değerindeyken gerçek pozitif oranı neredeyse 0.93 değerindeydi. Ayrıca yanlış pozitif oranı 1.0 iken gerçek pozitif oranı 1.0 değerine ulaştı. ROC eğrisi altında hesaplanan alan 0.96 olarak gözlemlenmiştir.




Şekil 7.6. Önerilen yöntemin ROC eğrisi

Şekil 7.7’de, önerilen yöntemin verdiği çeşitli bölütleme sonuçları görselleştirilmiştir. Şekil 7.7’nin ilk satırında giriş görüntüleri verilmiş, ikinci satırında ise maske sonuçları gösterilmiştir. Son satırda ise önerilen modelden elde edilen bölütleme sonuçları verilmiştir. Şekil 7.7’nin birinci, ikinci ve dördüncü sütunlarında gösterilen maske ve elde edilen bölütleme dikkate alındığında, üretilen bölütlemelerin maske bölümleri ile hemen hemen aynı olduğu görülmüştür. Ön plan nesnelerinin (gömülü diş) yalnızca birkaç pikseli, Şekil 7.7’nin üçüncü ve son sütunlarında gösterilen görüntüler için yanlışlıkla arka plan olarak sınıflandırılmıştır.



Şekil 7.7. Önerilen yöntemin bölütleme performansının görselleştirilmesi


Ayrıca, önerilen yöntemin ön plandaki nesneleri kaçırdığı veya alt bölütleme yaptığı durumlarda bazı bölütleme sonuçları görselleştirdik. Bu bölütleme Şekil 7.8’de verilmiştir. Şekil 7.7’ye benzer şekilde birinci ve ikinci satırlar sırasıyla giriş görüntülerini ve maske bölütlemelerini göstermektedir. Bunun ile birlikte üçüncü satırda önerilen modelden elde edilen bölütleme sonuçları verilmiştir. Birinci ve dördüncü sütunlarda görüldüğü gibi, maske görüntülerinde yalnızca bir ön plan nesnesi bulunurken, bölütleme sonuçlarında bir arka plan nesnesi yanlışlıkla ön plan nesnesi olarak bölütlenmiştir. Şekil 7.8’in ikinci sütununda, üç ön plan nesnesine sahip bir maske bölütlemesi verilmiştir. Karşılık gelen bölütleme sonucunda, iki ön plan nesnesi doğru bir şekilde algılanırken, bir ön plan nesnesinin birçok pikseli önerilen yaklaşım tarafından gözden kaçırılmıştır. Şekil 7.8’in 3. ve 5. sütunlarında verilen sonuçlara bakıldığında yetersiz bölütleme sonuçları görülmektedir.



Şekil 7.8. Yanlış bölütlemeler için bazı örnekler

Ayrıca bu çalışmada bu çalışmada önerilen modele bağlı olarak farklı yaklaşımlar geliştirilmiştir. Farklı U-Net modellerinin gömülü dışın panoramik görüntülerdeki bölütleme performansı üzerindeki etkisini daha da araştırdık. Oluşturulan çeşitli U-Net modelleri Şekil 7.9’da verilmiştir. Şekil 7.9 (a), değiştirilmiş ters çevrilmiş artık blok ve BConvLSTM bloklarının kullanılmadığı bir U-Net mimarisidir. Bu U-Net modelini oluşturmak için yalnızca basit artık blokları ve conv block yapısının kullanıldığı bir modeldir (ResU-Net). Şekil 7.9 (b), U-Net modeli sadece basit artık bloklardan oluşmamış, modelde değiştirilmiş ters çevrilmiş artık bloklar ve BConvLSTM de kullanılmıştır (Değiştirilmiş-Res/ BConvLSTMU-Net). Şekil 7.9 (c), U-Net

modelini oluşturmak için basit artık blokları ve BConvLSTM blokları kullanılmıştır (BConvLSTMU-Net). Bu modellerin performans sonuçları Tablo 7.2’de verilmiştir.




Şekil 7.9. Çalışmada kullanılan elemanların çeşitli U-Net modelleri: (a) ResU-Net, (b) Değiştirilmiş-Res/BConvLSTMU-Net, (c) BConvLSTMU-Net

Tablo 7.2. Bu çalışmada U-Net modelleri kullanılarak elde edilen doğrulukların özeti (Şekil 7.9)

Model	F1-skoru	IoU	Duyarlılık	Doğruluk
ResU-Net	0.8966	0.8125	0.8901	0.9978
BConvLSTMU-Net	0.9034	0.8238	0.8945	0.9979
Değiştirilmiş-Res/BConvLSTMU-Net	0.9074	0.8306	0.8991	0.9980
Önerilen ResMIBCU-Net	0.9159	0.8448	0.9071	0.9982

Tablo 7.2’de görüldüğü gibi, ResMIBCU-Net modeli sırasıyla en yüksek F1-skoru, IoU, duyarlılık ve doğruluk skorlarını üretti. Bu skorlar Tablo 7.2’de görüleceği üzere sırasıyla 0.9159, 0.8448, 0.9071 ve 0.9982 değerindedir. İkinci ve üçüncü en iyi başarılar sırasıyla Değiştirilmiş-Res/BConvLSTMU-Net ve BConvLSTMU-Net modelleri tarafından elde edildi. Son olarak, en kötü performans ResU-Net modeli tarafından elde edilmiştir. Bu sonuçlardan, BConvLSTM, değiştirilmiş ters artık blok ve conv block katmanlarının hibrit kullanımlarının performansı açıkça iyileştirdiği gözlemlenebilir.

Tablo 7.2’de sayısal değerlendirme başarımları verilirken, görsel değerlendirmeler Şekil 7.10’da verilmiştir. Maske görüntüleri ile elde edilen bölütlemeler karşılaştırıldığında, önerilen yöntemin neredeyse maske gibi özdeş ikili görüntüler ürettiği görülmüştür.



Şekil 7.10. ResU-Net, Değiştirilmiş-Res/BConvLSTMU-Net, BConvLSTMU-Net ve önerilen yöntem bölütleme sonuçları


Bu çalışmada elde edilen bölütleme sonuçlarını diğer U-Net mimarileri tarafından elde edilen bölütleme sonuçlarıyla da karşılaştırdık. Karşılaştırmalar F1-skoru, IoU, duyarlılık ve doğruluk metrikleri kullanılarak yapılmıştır. Hesaplanan değerlendirme ölçütleri Tablo 7.3'te verilmiştir.

Tablo 7.3. Önerilen yöntemin diğer U-Net tabanlı mimariler ile performans karşılaştırması

Model	F1-skoru	IoU	Duyarlılık	Doğruluk
U-Net [110]	0.8077	0.6774	0.7428	0.9962
ResBCU-Net [74]	0.8743	0.7767	0.8684	0.9973
BCDU-Net [144]	0.8759	0.7792	0.8857	0.9973
ResUNet++ [145]	0.8864	0.7960	0.8569	0.9976
ResMIBCU-Net	0.9159	0.8448	0.9071	0.9982

Tablo 7.3'te görüldüğü gibi, geleneksel U-Net [110] modeli, hesaplanan F1-skoru, IoU, duyarlılık ve doğruluk skorlarının sırasıyla 0.8077, 0.6774, 0.7428 ve 0.9962 olduğu daha kötü bölütleme sonuçları üretmiştir. ResUNet++ [145] yaklaşımı, 0.8864 F1-skoru, 0.7960 IoU değeri, 0.8569 duyarlılık skoru ve 0.9976 doğruluk skorunun elde edildiği en iyi ikinci bölütlemeleri üretti. İkinci ve üçüncü en iyi bölütlemeler sırasıyla BCDU-Net [144] ve ResBCU-Net [74] yöntemleriyle üretildi. Sonuç olarak, önerilen model diğer karşılaştırılan yöntemlerden daha iyi performans göstermiştir. Tablo 7.3'de sayısal değerlendirme başarımları verilirken, görsel değerlendirmeler Şekil 7.11'de verilmiştir.

Literatürde gömülü dışlerin tespiti ile ilgili yapılmış çok az çalışma vardır. Bu tespit çalışmalarında genellikle bölgesel tabanlı HB-ESA, DHB-ESA ve YOLO gibi yöntemler kullanılmıştır [37,40,41]. Ancak mevcut çalışmamızda, piksel tabanlı bir derin sinir ağı geliştirilmiştir. Bu nedenle, önerilen modelin performansını literatürde var olan çalışmalarla karşılaştırmak adil olmayacaktır. Sonuç olarak, önerilen modele dayalı bu çalışmanın gömülü dışlerin tespiti için piksel tabanlı çalışmalarda öncü olması hedeflenmektedir.



Şekil 7.11. Farklı mimariler ile önerilen modelin görsel bölütleme sonuçlarının karşılaştırılması

8. SONUÇLAR

Tıbbi görüntüleme teknolojisindeki gelişmeler ile cihaz tasarımları, sağlık alanında istihdam için önemli bir adımı oluşturmaktadır. Bu gelişmeler hastalıkların erken teşhis olanakları ve hassasiyet seviyeleri artırma ile birlikte hekimlerin iş yükünü azaltarak zaman kazandırmaktadır. Bu yüzden literatürdeki çalışmalarda sağlık alanında görüntü iyileştirmeleri ve tespit sistemleri büyük bir odak noktası olmuştur. Diş hekimliği hizmetleri genel itibarıyla ağız içi hastalıkların tanı, tedavi ve önlenmesini kapsayan sağlık sektöründeki en hızlı büyüyen alanlardan birisidir. Diş röntgenleri üzerine birçok araştırmacı, ön işlem ve bölütleme için çeşitli morfolojik işlemleri kullanan çalışmalar gerçekleştirmiştir. Çok iyi derecede sonuçlar elde edilerek diş hekimliği alanında, yazılımlarda kullanılacak tanı amaçlı sistemler mevcut değildir. Diş hekimlerinin genellikle çok sayıda hastaya hizmet etmesi gerekmektedir. Diş röntgenlerinin gözlemlenmesinde yorgunluk, anlık duygular ve düşük deneyim seviyeleri gibi kişisel faktörlerden dolayı yanlış tanı veya yetersiz tanıya neden olabilmektedir. Yapay zeka tabanlı tanı ve tespit sistemleri ile hem diş hekiminin yükü azaltılarak hem de ağız ve diş sağlığı açısından kalitenin artması sağlanabilmektedir.

Bu tez çalışması kapsamında diş röntgen görüntülerinde derin öğrenme ile hastalık ve materyal tespiti üzerine özgün yöntemler geliştirilmiştir. Literatürde bu konuya yönelik kullanılabilecek paylaşıma açık veri seti eksikliğinden dolayı özgün veri seti oluşturulmuştur. Bu veri seti, ileride yapılacak benzer araştırmalar için bir referans kaynağı olabilecek niteliktedir. Aynı zamanda diş sağlığı alanında daha iyi teşhis ve tedavi yöntemlerinin geliştirilmesine katkı sağlamayı hedeflemektedir. Oluşturulan veri setleri ile 4 ayrı problemin çözümüne yönelik derin öğrenme tabanlı modeller tasarlanmıştır. Bu yöntemlerde günümüzde oldukça popüler olan ESA mimarileri, DHB-ESA, artık bloklar ve dönüştürücüler gibi güncel modüller kullanılmıştır. Önerilen yöntemlerde elde edilen sonuçlar tıp alanında teşhis süreçlerine katkı sağlayacak ve gelecekteki araştırmalar için temel oluşturacak önemli bulgular sunmaktadır.

Bölüm 4'te panoramik diş röntgen görüntülerinde diş materyallerini tespit etmek için yeni bir yaklaşım önerilmiştir. Geliştirilen yaklaşım kapsamında; girdi olarak kullanılan panoramik diş röntgen görüntüleri, gürültü giderme için başlangıçta ön işleme tabi tutulur ve derin bir öğrenme yaklaşımı kullanılarak diş bölgesi belirlenmektedir. Bu amaçla daha DHB-ESA yöntemi kullanılmıştır. Diş bölgesinin tam yerini belirlemek için DHB-ESA uygulandıktan sonra, bir diş bölgesi düzeltme yaklaşımı uygulanır. Çünkü DHB-ESA bir doğru diş bölgesinden daha fazla diş bölgesi üretebilir. Diş bölgesini ön plan ve arka plan bölgelerine bölmek için Graf Kesim (GK) tabanlı görüntü bölütleme uygulanmıştır. Son olarak diş problemini belirlemek için şekle dayalı öznitelik çıkarımı ve sınıflandırma işlemine tabi tutulmuştur. Elde edilen sonuçlar gözlemlendiğinde önerilen iki adımdan oluşan yaklaşım basit ama oldukça etkilidir. Bu uygulama köprü, kaplama ve dolgu gibi diş malzemelerinin tespiti için yapılan öncü çalışmalardan birisidir.

Diş bölgelerinin tespiti %100 doğruluk skoru ile sağlanmıştır. Ayrıca köprü, kaplama ve dolgudan oluşan 3 farklı sınıf için en yüksek başarımlar %92.8 doğruluk ile DVM sınıflandırıcısı ile elde edilmiştir. Bu sonuçların diğer hastalıkların tespiti ile ilgili çalışmalara katkı sağlayacağı düşünülmektedir. Önerilen sistem kullanılarak yapılan deneysel çalışmalarda elde edilen yüksek performans oranı, gerçek zamanlı uygulamalarda kullanılabilirliğini göstermiştir. Önerilen çalışmanın bölütleme adımı, arka plan ve diş bölgelerinin belirlendiği GK'ya dayanmaktadır. Bu işlem söz konusu bölgelerin manuel olarak belirlenmesini zorunlu kılmaktadır. Bu durum, önerilen çalışmanın bir sınırlılığı olarak yorumlanabilir ve ileriki çalışmalarda medikal tanı sistemlerinde otomatik bir bölütleme işlemi dikkate alınacağı modeller geliştirilecektir.

Bölüm 5'te periapikal görüntülere dayalı olarak diş çürüğünün otomatik tespiti için yeni bir yaklaşım önermiştir. Önerilen yaklaşım, ÇG-DESAT modeli kullandı. Spesifik olarak, önerilen ÇG-DESAT yönteminin başarısını artırmak için skora dayalı bir birleştirme tekniği kullanıldı. Önerilen yaklaşımın girdileri hem ham periapikal görüntüler hem de ön işleme tabi tutularak işlenmiş bir biçimi kullanılmıştır. Skor tabanlı birleştirme, önerilen çok girişli ESA mimarisinin Softmax katmanında gerçekleştirilmektedir. Bu çalışmada kullanılan keskinleştirme filtresi ve yoğunluk renk haritası yaklaşımı ile işlenmemiş diş görüntülerinde çürümüş alanı daha da belirginleştirdiği gözlemlenmiştir. Literatürde diş çürüğü ile ilgili çalışmalar olmasına rağmen halka açık bir veri seti bulunmamaktadır. Bu uygulamada, 340 (çürük ve çürük olmayan) görüntüden oluşan yeni bir veri seti sunulmuştur. Diş çürüğü tespitinde transfer öğrenme yaklaşımına dayalı önceden eğitilmiş AlexNet mimarisi uyarlanmıştır. Bu çalışmada, sınırlı sayıda görüntü içeren bir veri seti kullanılarak rastgele ağırlıklarla eğitim sürecine başlamak yerine, önceden eğitilmiş mimarinin öğrenilmiş ağırlıkları kullanılmıştır. Deneysel sonuçlarda, önerilen model için kullanılan transfer öğrenme tabanlı AlexNet modelinin sıfırdan eğitim yaklaşımına göre başarıyı yaklaşık %10 arttırdığı gözlemlenmiştir. Önerilen ÇG-DESAT modeli, %99.13'lük bir doğruluk ile diş çürüklerini tespit etmede kayda değer bir başarı elde etmiştir. Bu sonuç, önerilen modelin gerçek zamanlı uygulamalarda kullanılabilirliğini göstermektedir.

Bölüm 6'da maksiller sinüs tanısı için swin transformatör ve UNet tabanlı "Res-Swin-Unet" adlı yeni bir yaklaşım önerilmiştir. Maksiller tespiti için kendi kendine dikkat mekanizmasını kullanan en son teknoloji Swin transformatör modeline dayalı yeni bir yaklaşımdır. Önerilen mimari, ResNet tabanlı bir kodlayıcı ve Swin transformatör tabanlı kod çözücü birimlerinden oluşmaktadır. Önerilen ağırlı kodlayıcı kısmında, güçlü başlangıç özniteliklerini çıkarmak için ResNet ağ mimarisi kullanılmıştır. Böylece, sınırlı sayıda görüntü için daha verimli başlangıç öznitelikleri çıkarma imkânı sağlanmıştır. Kod çözücü bölümünde öz dikkat tabanlı swin transformatör blokları ile küresel bağlam öznitelikleri çıkarılmıştır. Önerilen ağırlı son katmanında evrişim ve sigmoid aktivasyon fonksiyonu ile sinüs enfeksiyonu tespiti yapılmıştır. Önerilen modelin performansını değerlendirmek için oluşturulan, 298 KIBT görüntüsü içeren etiketli bir

özgün veri seti kullanılmıştır. ResNet 18, ResNet 34, ResNet 50 ve ResNet 101 mimarilerini omurga ağları olarak kullanıldığı sistemde %84.71 IoU, %91.72 F1-skoru, %91.57 kesinlik, %91.87 duyarlılık, %99.87 doğruluk ve %99.18 AUC başarımı ile en yüksek performans sonuçlarını Resnet 101 mimarisi vermiştir. Deneysel çalışmalar, önerilen modelin maksiller sinüs saptanmasında etkili bir şekilde katkıda bulunabileceğini göstermektedir.

Bölüm 7’de panoramik diş röntgen görüntülerinden gömülü diş tespiti için U-Net mimarisine dayalı ResMIBCU-Net adında bir bölütleme modeli önerilmiştir. İlk olarak daha iyi özellik birikimine odaklanmak için kodlayıcı bölümünde artık bloklar, değiştirilmiş ters çevrilmiş artık blok ve son olarak “conv block” olarak adlandırılan bir katman kullanılarak genişletilmiş bir artık ağ önermekteyiz. Değiştirilmiş ters çevrilmiş artık blok MobileNetV2 bloğunun modifiye edilmiş bir versiyonudur. Bu, sinir ağının alt katmanlarındaki görüş alanını artırarak, hassas alt düzey özellikleri çıkarmalarına olanak tanımaktadır. İkinci adımda ise kod çözümü modülünün farklı bloklardan çıkarılan özelliklerin birleştirildiği, BConvLSTM ve conv block katmanının kullanıldığı verimli bir omurga ve geliştirilmiş atlama yolları içermektedir. BConvLSTM bloğunun, kodlayıcı/kod çözücü arasındaki uzamsal bilgileri koruyarak bölütlemeyi iyileştirmek için bağlantının omurgasında kullanıldığı bir yapı oluşturulmuştur. Önerilen yöntemde, %99.82 doğruluk, %91.59 F1-skoru, %84.48 IoU ve %90.71 duyarlılık başarımları elde edilmiştir. Elde edilen deneysel sonuçlara bakıldığında önerilen modelin gömülü dişlerin tespitinde daha iyi ayırt edici bilgileri yakalayabildiğini göstermektedir. Bu sonuçlara göre önerilen yaklaşımların gerçek dünya uygulamalarında kullanılabileceği kanıtlanmıştır. Bu tez çalışmasında önerilen derin öğrenme yöntemlerinin diş röntgen görüntülerinde hastalık ve materyal tespiti gibi önemli tıbbi uygulamalarda başarılı bir şekilde kullanılabileceğini vurgulamaktadır.

ÖNERİLER

ESA, görüntü işleme, nesne tanıma ve sınıflandırma gibi birçok görevde etkili sonuçlar elde etmek için kullanılan güçlü bir araçtır. Bu tez çalışmasında önerilen yöntemlerin derin öğrenme teknikleriyle diş röntgen görüntülerinde hastalık ve materyal tespiti konusunda daha iyi performans sağladığı ve gelecekteki çalışmalar için önemli bir temel oluşturduğu söylenebilir. Diş röntgen görüntüleri üzerine çalışmalarda veri seti eksikliği literatürde yaygın bir sorundur. Bu nedenle, benzer çalışmalar için daha geniş ve çeşitlendirilmiş veri setleri oluşturulabilir. Farklı hastalık tipleri, materyallerde implant çeşitleri ve potansiyel anormallikleri içeren daha fazla görüntünün toplanması ve etiketlenmesi önemlidir. Genişleyen veri seti sayesinde, derin öğrenme algoritmalarının daha genel ve kapsamlı bir şekilde test edilmesini sağlayacaktır. Önerilen modellerin performansını artırmak için farklı mimariler, hiper parametre ayarları ve optimizasyon teknikleri denenebilir.

Bu tez çalışmasındaki uygulamalar, diş röntgen görüntülerinde hastalık ve materyal tespiti üzerine odaklanmaktadır. Ancak, benzer bir yaklaşımın diğer medikal görüntüleme yöntemleri veya farklı uygulama alanları için de uygulanması düşünülebilir. Bu, derin öğrenme tekniklerinin tıbbi teşhis ve görüntüleme alanında daha geniş bir etki potansiyeline sahip olması sağlanabilir. Yeni ve yenilikçi yaklaşımların keşfi, bu alanda daha ileriye gitmek için önemlidir. Bu bağlamda, tez çalışmasının sonuçları, gelecekteki araştırmalara rehberlik etmek ve yeni yaklaşımların geliştirilmesine ilham vermek için değerli bir kaynak olabilir. Önemli tıbbi uygulamalarda alanın gelişmeye açık olduğu ve yeni yaklaşımların potansiyelini barındırdığı unutulmamalıdır.

KAYNAKLAR

- [1] S.C. White, M.J. Pharoah, Oral radiology-E-Book: Principles and interpretation, Oral Radiology-E-Book: Principles and Interpretation, Elsevier Health Sciences. (2014).
- [2] T. Sakurai, R. Kawamata, Y. Kozai, Y. Kaku, K. Nakamura, M. Saito, H. Wakao, I. Kashima, Relationship between radiation dose reduction and image quality change in photostimulable phosphor luminescence X-ray imaging systems, *Dentomaxillofacial Radiology*. 39 (2010) 207–215. <https://doi.org/10.1259/DMFR/44413341>.
- [3] A.J. Solanki, P.M. Mahant, A Review on Dental Radiographic Images, *Int J Eng Res Appl*. 07 (2017) 49–53. <https://doi.org/10.9790/9622-0707074953>.
- [4] G. Fahmy, D. Nassar, E. Haj-Said, H. Chen, O. Nomir, J. Zhou, R. Howell, H.H. Ammar, M. Abdel-Mottaleb, A.K. Jain, Towards an Automated Dental Identification System (ADIS), in: *In International Conference on Biometric Authentication*, Springer, Berlin, Heidelberg, 2004: pp. 789–796. https://doi.org/10.1007/978-3-540-25948-0_107.
- [5] M. Noujeim, T. Prihoda, W.D. McDavid, K. Ogawa, K. Seki, T. Okano, T. Sue, R.P. Langlais, Pre-clinical evaluation of a new dental panoramic radiographic system based on tomosynthesis method, *Dentomaxillofacial Radiology*. 40 (2011) 42–46. <https://doi.org/10.1259/DMFR/73312141>.
- [6] D.-N. Le, V.S. Parvathy, D. Gupta, A. Khanna, J.J.P.C. Rodrigues, K. Shankar, IoT enabled depthwise separable convolution neural network with deep support vector machine for COVID-19 diagnosis and classification, *International Journal of Machine Learning and Cybernetics*. 12 (2021) 3235–3248. <https://doi.org/10.1007/S13042-020-01248-7>.
- [7] J.C.M. Román, V.R. Fretes, C.G. Adorno, R.G. Silva, J.L.V. Noguera, H. Legal-Ayala, J.D. Mello-Román, D.R.E. Torres, J. Facon, Panoramic dental radiography image enhancement using multiscale mathematical morphology, *Sensors*. 21 (2021) 3110. <https://doi.org/10.3390/s21093110>.
- [8] S.A. Ahmad, M.N. Taib, N.E.A. Khalid, R. Ahmad, H. Taib, Performance of compound enhancement algorithms on dental radiograph images, In *International Conference on Medical Image and Signal Computing ICMISC*. (2011) 23–25.
- [9] S.G.S. Simon, X.F. Joseph, A.T. Waktola, D. Senay, A Novel Method of Pre-processing Using Dental X-Ray Images by Adaptive Morpho Histo Wavelet Denoising (AMHW) Method, *Communications in Computer and Information Science*. 1026 (2019) 3–10. https://doi.org/10.1007/978-3-030-26630-1_1.
- [10] R. Kaur, R.S. Sandhu, A. Gera, T. Kaur, Edge detection in digital panoramic dental radiograph using improved morphological gradient and MATLAB, *Proceedings of the 2017 International Conference On Smart Technology for Smart Nation, SmartTechCon 2017*. (2018) 793–797. <https://doi.org/10.1109/SMARTTECHCON.2017.8358481>.
- [11] J. Naam, J. Harlan, Madenda S., E.P. Wibowo, Identification of the proximal caries of dental x-ray image with multiple morphology gradient method, *Int J Adv Sci Eng Inf Technol*. 6 (2016) 343–346.

- [12] R. Obuchowicz, K. Nurzynska, B. Obuchowicz, A. Urbanik, A. Piórkowski, Caries detection enhancement using texture feature maps of intraoral radiographs, *Oral Radiol.* 36 (2020) 275–287. <https://doi.org/10.1007/S11282-018-0354-8>.
- [13] J. Na'am, J. Harlan, S. Madenda, E.P. Wibowo, Image processing of panoramic dental X-ray for identifying proximal caries, *Indonesian Journal of Electrical Engineering and Computer Science (Telkomnika)*. 15 (2017) 702–708.
- [14] V. Geetha, K.S. Aprameya, D.M. Hinduja, Dental caries diagnosis in digital radiographs using back-propagation neural network, *Health Inf Sci Syst.* 8 (2020) 1–14. <https://doi.org/10.1007/S13755-019-0096-Y>.
- [15] S.A. Prajapati, R. Nagaraj, S. Mitra, Classification of dental diseases using CNN and transfer learning, in: In 2017 5th International Symposium on Computational and Business Intelligence (ISCBI), IEEE, Dubai, United Arab Emirates, 2017: pp. 70–74. <https://doi.org/10.1109/ISCBI.2017.8053547>.
- [16] P. Singh, P. Sehgal, Automated caries detection based on Radon transformation and DCT, in: 2017 8th International Conference on Computing, Communication and Networking Technologies (ICCCNT), IEEE, Delhi, India, 2017: pp. 1–6. <https://doi.org/10.1109/ICCCNT.2017.8204030>.
- [17] F. Casalegno, T. Newton, R. Daher, M. Abdelaziz, A. Lodi-Rizzini, F. Schürmann, I. Krejci, H. Markram, Caries detection with near-infrared transillumination using deep learning, *J Dent Res.* 98 (2019) 1227–1233. <https://doi.org/10.1177/0022034519871884>.
- [18] A.G. Cantu, S. Gehrun, J. Krois, A. Chaurasia, J.G. Rossi, R. Gaudin, K. Elhennawy, F. Schwendicke, Detecting caries lesions of different radiographic extension on bitewings using deep learning, *J Dent.* 100 (2020) 103425. <https://doi.org/10.1016/J.JDENT.2020.103425>.
- [19] S. Datta, N. Chaki, B. Modak, Neutrosophic Set-Based Caries Lesion Detection Method to Avoid Perception Error, *SN Comput Sci.* 1 (2020) 1–15. <https://doi.org/10.1007/S42979-020-0066-0/FIGURES/9>.
- [20] L.H. Son, T.M. Tuan, H. Fujita, N. Dey, A.S. Ashour, V.T.N. Ngoc, L.Q. Anh, D.T. Chu, Dental diagnosis from X-Ray images: An expert system based on fuzzy computing, *Biomed Signal Process Control.* 39 (2018) 64–73. <https://doi.org/10.1016/J.BSPC.2017.07.005>.
- [21] M.M. Lakshmi, P. Chitra, Tooth Decay Prediction and Classification from X-Ray Images using Deep CNN, *Proceedings of the 2020 IEEE International Conference on Communication and Signal Processing, ICCSP 2020.* (2020) 1349–1355. <https://doi.org/10.1109/ICCSP48568.2020.9182141>.
- [22] Ș. Oprea, C. Marinescu, I. Liță, M. Jurianu, D.A. Vișan, I.B. Cioc, Image processing techniques used for dental x-ray image analysis, 2008 31st International Spring Seminar on Electronics Technology: Reliability and Life-Time Prediction, ISSE 2008. (2008) 125–129. <https://doi.org/10.1109/ISSE.2008.5276424>.
- [23] J.H. Lee, D.H. Kim, S.N. Jeong, S.H. Choi, Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm, *J Dent.* 77 (2018) 106–111. <https://doi.org/10.1016/J.JDENT.2018.07.015>.

- [24] L. Megalan Leo, T. Kalapalatha Reddy, Learning compact and discriminative hybrid neural network for dental caries classification, *Microprocess Microsyst.* 82 (2021) 103836. <https://doi.org/10.1016/J.MICPRO.2021.103836>.
- [25] Y.P. Huang, S.Y. Lee, Deep learning for caries detection using optical coherence tomography, *MedRxiv.* (2021). <https://doi.org/10.1101/2021.05.04.21256502>.
- [26] T.H. Bui, K. Hamamoto, M.P. Paing, Deep Fusion Feature Extraction for Caries Detection on Dental Panoramic Radiographs, *Applied Sciences* . 11 (2021) 2005. <https://doi.org/10.3390/APP11052005>.
- [27] V. Majanga, S. Viriri, Automatic Blob Detection for Dental Caries, *Applied Sciences* . 11 (2021) 9232. <https://doi.org/10.3390/APP11199232>.
- [28] S. Vinayahalingam, S. Kempers, L. Limon, D. Deibel, T. Maal, M. Hanisch, S. Bergé, T. Xi, Classification of caries in third molars on panoramic radiographs using deep learning, *Scientific Reports* . 11 (2021) 1–7. <https://doi.org/10.1038/s41598-021-92121-2>.
- [29] S.K. Jung, H.K. Lim, S. Lee, Y. Cho, I.S. Song, Deep Active Learning for Automatic Segmentation of Maxillary Sinus Lesions Using a Convolutional Neural Network, *Diagnostics* . 11 (2021) 688. <https://doi.org/10.3390/DIAGNOSTICS11040688>.
- [30] M. Mori, Y. Arij, A. Katsumata, T. Kawai, K. Araki, K. Kobayashi, E. Arij, A deep transfer learning approach for the detection and diagnosis of maxillary sinusitis on panoramic radiographs, *Odontology*. 109 (2021) 941–948. <https://doi.org/10.1007/S10266-021-00615-2/FIGURES/4>.
- [31] M. Murata, Y. Arij, Y. Ohashi, T. Kawai, M. Fukuda, T. Funakoshi, Y. Kise, M. Nozawa, A. Katsumata, H. Fujita, E. Arij, Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography, *Oral Radiol.* 35 (2019) 301–307. <https://doi.org/10.1007/S11282-018-0363-7/FIGURES/4>.
- [32] H.G. Kim, K.M. Lee, E.J. Kim, J.S. Lee, Improvement diagnostic accuracy of sinusitis recognition in paranasal sinus X-ray using multiple deep learning models, *Quant Imaging Med Surg.* 9 (2019) 942. <https://doi.org/10.21037/QIMS.2019.05.15>.
- [33] R. Kuwana, Y. Arij, M. Fukuda, Y. Kise, M. Nozawa, C. Kuwada, C. Muramatsu, A. Katsumata, H. Fujita, E. Arij, Performance of deep learning object detection technology in the detection and diagnosis of maxillary sinus lesions on panoramic radiographs, *Dentomaxillofacial Radiology*. 50 (2020) 20200171. <https://doi.org/10.1259/DMFR.20200171/ASSET/IMAGES/LARGE/DMFR.20200171.G002.JPEG>
- [34] Y. Kim, K.J. Lee, L. Sunwoo, D. Choi, C.M. Nam, J. Cho, J. Kim, Y.J. Bae, R.E. Yoo, B.S. Choi, C. Jung, J.H. Kim, Deep Learning in Diagnosis of Maxillary Sinusitis Using Conventional Radiography, *Invest Radiol.* 54 (2019) 7–15. <https://doi.org/10.1097/RLI.0000000000000503>.
- [35] Y. Ohashi, Y. Arij, A. Katsumata, H. Fujita, M. Nakayama, M. Fukuda, M. Nozawa, E. Arij, Utilization of computer-aided detection system in diagnosing unilateral maxillary sinusitis on panoramic radiographs, *Dentomaxillofacial Radiology*. 45 (2016). <https://doi.org/10.1259/DMFR.20150419/ASSET/IMAGES/LARGE/DMFR.20150419.G002.JPEG>
- [36] K. Orhan, E. Bilgir, I.S. Bayrakdar, M. Ezhov, M. Gusarev, E. Shumilov, Evaluation of artificial intelligence for detecting impacted third molars on cone-beam computed tomography scans, *J*

- Stomatol Oral Maxillofac Surg. 122 (2021) 333–337. <https://doi.org/10.1016/J.JORMAS.2020.12.006>.
- [37] J. Faure, A. Engelbrecht, Impacted Tooth Detection in Panoramic Radiographs, *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 12861 (2021) 525–536. https://doi.org/10.1007/978-3-030-85030-2_43/COVER.
- [38] C. Kuwada, Y. Arij, M. Fukuda, Y. Kise, H. Fujita, A. Katsumata, E. Arij, Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs, *Oral Surg Oral Med Oral Pathol Oral Radiol*. 130 (2020) 464–469. <https://doi.org/10.1016/J.OOOO.2020.04.813>.
- [39] W. Zhang, J. Li, Z.-B. Li, Z. Li, Predicting postoperative facial swelling following impacted mandibular third molars extraction by using artificial neural networks evaluation , *Sci Rep*. 8 (2018) 9–1. <https://doi.org/10.1038/s41598-018-29934-1>.
- [40] M. Başaran, Ö. Çelik, I.S. Bayrakdar, E. Bilgir, K. Orhan, A. Odabaş, A.F. Aslan, R. Jagtap, Diagnostic charting of panoramic radiography using deep-learning artificial intelligence system, *Oral Radiol*. 38 (2022) 363–369. <https://doi.org/10.1007/S11282-021-00572-0/TABLES/2>.
- [41] M.E. Celik, Deep Learning Based Detection Tool for Impacted Mandibular Third Molar Teeth, *Diagnostics* . 12 (2022) 942. <https://doi.org/10.3390/DIAGNOSTICS12040942>.
- [42] M. Fukuda, K. Inamoto, N. Shibata, Y. Arij, Y. Yanashita, S. Kutsuna, K. Nakata, A. Katsumata, H. Fujita, E. Arij, Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography, *Oral Radiol*. 36 (2020) 337–343. <https://doi.org/10.1007/S11282-019-00409-X/FIGURES/6>.
- [43] S. Vinayahalingam, T. Xi, S. Bergé, T. Maal, G. de Jong, Automated detection of third molars and mandibular nerve by deep learning, *Sci Rep*. 9 (2019) 1–7. <https://doi.org/10.1038/s41598-019-45487-3>.
- [44] N. Banar, J. Bertels, F. Laurent, R.M. Boedi, J. De Tobel, P. Thevissen, D. Vandermeulen, Towards fully automated third molar development staging in panoramic radiographs, *Int J Legal Med*. 134 (2020) 1831–1841. <https://doi.org/10.1007/S00414-020-02283-3/TABLES/4>.
- [45] T. Ekert, J. Krois, L. Meinhold, K. Elhennawy, R. Emara, T. Golla, F. Schwendicke, Deep Learning for the Radiographic Detection of Apical Lesions, *J Endod*. 45 (2019) 917–922.e5. <https://doi.org/10.1016/J.JOEN.2019.03.016>.
- [46] S. Tajima, Y. Okamoto, T. Kobayashi, M. Kiwaki, C. Sonoda, K. Tomie, H. Saito, Y. Ishikawa, S. Takayoshi, Development of an automatic detection model using artificial intelligence for the detection of cyst-like radiolucent lesions of the jaws on panoramic radiographs with small training datasets, *J Oral Maxillofac Surg Med Pathol*. 34 (2022) 553–560. <https://doi.org/10.1016/J.AJOMS.2022.02.004>.
- [47] A. Imak, A. Çelebi, M. Türkoğlu, A. Şengür, Dental Material Detection based on Faster Regional Convolutional Neural Networks and Shape Features, *Neural Process Lett*. 54 (2022) 2107–2126. <https://doi.org/10.1007/S11063-021-10721-5/FIGURES/15>.

- [48] A. Imak, A. Celebi, K. Siddique, M. Turkoglu, A. Sengur, I. Salam, Dental Caries Detection Using Score-Based Multi-Input Deep Convolutional Neural Network, *IEEE Access*. 10 (2022) 18320–18329. <https://doi.org/10.1109/ACCESS.2022.3150358>.
- [49] A. Çelebi, A. Imak, H. Üzen, Ü. Budak, M. Türkoğlu, D. Hanbay, A. Şengür, Maxillary Sinus Detection on Cone Beam Computed Tomography Images using ResNet and Swin Transformer-based UNet, *Oral Surg Oral Med Oral Pathol Oral Radiol*. (2023). <https://doi.org/10.1016/J.OOOO.2023.06.001>.
- [50] A. Imak, A. Çelebi, O. Polat, M. Türkoğlu, A. Şengür, ResMIBCU-Net: an encoder–decoder network with residual blocks, modified inverted residual block, and bi-directional ConvLSTM for impacted tooth segmentation in panoramic X-ray images, *Oral Radiol*. 1 (2023) 1–15. <https://doi.org/10.1007/S11282-023-00677-8/FIGURES/11>.
- [51] E. Ayaz, Bulaşıcı Olmayan Kronik Hastalıklar ile Ağız ve Diş Hastalıkları Arasındaki İlişkinin İncelenmesi, Yüksek Lisans Tezi, Tekirdağ Namık Kemal Üniversitesi, Sosyal Bilimler Enstitüsü, 2019.
- [52] K. Kamburoğlu, E. Kolsuz, S. Murat, S. Yüksel, T. Özen, Proximal caries detection accuracy using intraoral bitewing radiography, extraoral bitewing radiography and panoramic radiography, *Http://Dx.Doi.Org/10.1259/Dmfr/30526171*. 41 (2014) 450–459. <https://doi.org/10.1259/DMFR/30526171>.
- [53] N.V. Penumatsa, S. Nallanchakrava, R. Muppa, A. Dandempally, P. Panthula, Conservative Approach in the Management of Radicular Cyst in a Child: Case Report, *Case Rep Dent*. 2013 (2013) 1–3. <https://doi.org/10.1155/2013/123148>.
- [54] M. Maillet, W.R. Bowles, S.L. McClanahan, M.T. John, M. Ahmad, Cone-beam Computed Tomography Evaluation of Maxillary Sinusitis, *J Endod*. 37 (2011) 753–757. <https://doi.org/10.1016/J.JOEN.2011.02.032>.
- [55] W.W. Johnson, The history of prosthetic dentistry, *J Prosthet Dent*. 9 (1959) 841–846. [https://doi.org/10.1016/0022-3913\(59\)90049-6](https://doi.org/10.1016/0022-3913(59)90049-6).
- [56] P.E. Petersen, The World Oral Health Report 2003: continuous improvement of oral health in the 21st century – the approach of the WHO Global Oral Health Programme, *Community Dent Oral Epidemiol*. 31 (2003) 3–24. <https://doi.org/10.1046/J.2003.COM122.X>.
- [57] Ö. İnık, E. Ülker, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*. 6 (2017) 85–104.
- [58] M. Türkoğlu, Görüntü İşleme Tabanlı Bitki Türleri ve Hastalıkları Tanıma, Doktora Tezi, İnönü Üniversitesi, Fen Bilimleri Enstitüsü, 2019.
- [59] G.E. Hinton, S. Osindero, Y.W. Teh, A Fast Learning Algorithm for Deep Belief Nets, *Neural Comput*. 18 (2006) 1527–1554. <https://doi.org/10.1162/NECO.2006.18.7.1527>.
- [60] R. Salakhutdinov, H. Larochelle, Efficient Learning of Deep Boltzmann Machines, In *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*. (2010) 693–700.
- [61] A. Krizhevsky, I. Sutskever, G.E. Hinton, ImageNet classification with deep convolutional neural networks, *Adv Neural Inf Process Syst*. 25 (2012) 1097–1105. <https://doi.org/10.1145/3065386>.

- [62] Y. Kahraman, Deep Learning Based Fabric Defect Detection, Ph.D. Thesis, Gaziantep University, Graduate School Of Natural and Applied Sciences, 2022.
- [63] M. Turkoglu, D. Hanbay, A. Sengur, Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests, *J Ambient Intell Humaniz Comput.* 13 (2022) 3335–3345. <https://doi.org/10.1007/S12652-019-01591-W/TABLES/6>.
- [64] M. Türkoğlu, D. Hanbay, Plant disease and pest detection using deep learning-based features, *Turkish Journal of Electrical Engineering & Computer Sciences.* 27 (2019) 1636–1651. <https://doi.org/10.3906/elk-1809-181>.
- [65] M. Turkoglu, D. Hanbay, Plant recognition system based on deep features and color-LBP method, 27th Signal Processing and Communications Applications Conference, SIU 2019. (2019). <https://doi.org/10.1109/SIU.2019.8806592>.
- [66] H. Üzen, İmalat Sistemlerinde Derin Öğrenme Tabanlı Doku Hata Tespiti, Doktora Tezi, İnönü Üniversitesi, Fen Bilimleri Enstitüsü, 2022.
- [67] D. Wei, B. Zhou, A. Torralba, W. T. Freeman, mneuron: A matlab plugin to visualize neurons from deep models, <https://Donglaiw.Github.io/Proj/Mneuron/Index.Html>. (2022).
- [68] H. Dong, K. Song, Y. He, J. Xu, Y. Yan, Q. Meng, PGA-Net: Pyramid Feature Fusion and Global Context Attention Network for Automated Surface Defect Detection, *IEEE Trans Industr Inform.* 16 (2020) 7448–7458. <https://doi.org/10.1109/TII.2019.2958826>.
- [69] M. Turkoglu, O.F. Alcin, M. Aslan, A. Al-Zebari, A. Sengur, Deep rhythm and long short term memory-based drowsiness detection, *Biomed Signal Process Control.* 65 (2021) 102364. <https://doi.org/10.1016/J.BSPC.2020.102364>.
- [70] F. Doğan, İ. Türkoğlu, Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması, *Sakarya University Journal of Computer and Information Sciences.* 1 (2018) 10–21. <http://saucis.sakarya.edu.tr/en/pub/saucis/issue/37127/427798> (accessed May 12, 2023).
- [71] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu, M.S. Lew, Deep learning for visual understanding: A review, *Neurocomputing.* 187 (2016) 27–48. <https://doi.org/10.1016/J.NEUCOM.2015.09.116>.
- [72] Y. Lecun, Y. Bengio, G. Hinton, Deep learning, *Nature.* 521 (2015) 436–444. <https://doi.org/10.1038/nature14539>.
- [73] E. Cengil, İki Boyutlu Sağlık, Tarım ve İş Güvenliği İmgeleri Üzerinde Sınıflandırma ve Nesne Tespiti, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2021.
- [74] N. Badshah, A. Ahmad, ResBCU-Net: Deep learning approach for segmentation of skin images, *Biomed Signal Process Control.* 71 (2022) 103137. <https://doi.org/10.1016/J.BSPC.2021.103137>.
- [75] W. Boulila, H. Ghandorh, M.A. Khan, F. Ahmed, J. Ahmad, A novel CNN-LSTM-based approach to predict urban expansion, *Ecol Inform.* 64 (2021) 101325. <https://doi.org/10.1016/J.ECOINF.2021.101325>.
- [76] M. Türkoğlu, D. Hanbay, Apricot Disease Identification based on Attributes Obtained from Deep Learning Algorithms, 2018 International Conference on Artificial Intelligence and Data Processing, IDAP 2018. (2019). <https://doi.org/10.1109/IDAP.2018.8620831>.
- [77] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, L.-C. Chen, MobileNetV2: Inverted Residuals and Linear Bottlenecks, (2018) 4510–4520.

- [78] Y. Li, D. Zhang, D.J. Lee, IIRNet: A lightweight deep neural network using intensely inverted residuals for image recognition, *Image Vis Comput.* 92 (2019) 103819. <https://doi.org/10.1016/J.IMAVIS.2019.10.005>.
- [79] H. Uzen, M. Turkoglu, D. Hanbay, Texture defect classification with multiple pooling and filter ensemble based on deep neural network, *Expert Syst Appl.* 175 (2021) 114838. <https://doi.org/10.1016/J.ESWA.2021.114838>.
- [80] E. Deniz, A. Şengür, Z. Kadiroğlu, Y. Guo, V. Bajaj, Ü. Budak, Transfer learning based histopathologic image classification for breast cancer detection, *Health Inf Sci Syst.* 6 (2018) 1–7. <https://doi.org/10.1007/S13755-018-0057-X/TABLES/5>.
- [81] M. Turkoglu, COVIDetectioNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble, *Applied Intelligence.* 51 (2021) 1213–1226. <https://doi.org/10.1007/S10489-020-01888-W/TABLES/9>.
- [82] L. Alzubaidi, J. Zhang, A.J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaría, M.A. Fadhel, M. Al-Amidie, L. Farhan, Review of deep learning: concepts, CNN architectures, challenges, applications, future directions, *Journal of Big Data.* 8 (2021) 1–74. <https://doi.org/10.1186/S40537-021-00444-8>.
- [83] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, 3rd International Conference on Learning Representations, ICLR 2015- Conference Track Proceedings. (2015).
- [84] F.N. Iandola, S. Han, M.W. Moskewicz, K. Ashraf, W.J. Dally, K. Keutzer, SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size, (2016). <https://arxiv.org/abs/1602.07360v4> (accessed May 12, 2023).
- [85] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, Going Deeper With Convolutions, (2015) 1–9.
- [86] F. Chollet, Xception: Deep Learning With Depthwise Separable Convolutions, (2017) 1251–1258.
- [87] J. Redmon, A. Farhadi, YOLO9000: Better, Faster, Stronger, (2017) 7263–7271.
- [88] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna, Rethinking the Inception Architecture for Computer Vision, (2016) 2818–2826.
- [89] X. Zhang, X. Zhou, M. Lin, J. Sun, ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices, (2018) 6848–6856.
- [90] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2016-December (2016) 770–778. <https://doi.org/10.1109/CVPR.2016.90>.
- [91] M. Tan, Q. V Le, EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, (2019) 6105–6114.
- [92] G. Huang, Z. Liu, L. van der Maaten, K.Q. Weinberger, Densely Connected Convolutional Networks, (2017) 4700–4708.
- [93] W. Fang, C. Wang, X. Chen, W. Wan, H. Li, S. Zhu, Y. Fang, B. Liu, Y. Hong, Recognizing Global Reservoirs From Landsat 8 Images: A Deep Learning Approach, *IEEE J Sel Top Appl Earth Obs Remote Sens.* 12 (2019) 3168–3177. <https://doi.org/10.1109/JSTARS.2019.2929601>.

- [94] L.D. Nguyen, D. Lin, Z. Lin, J. Cao, Deep CNNs for microscopic image classification by exploiting transfer learning and feature concatenation, *Proceedings - IEEE International Symposium on Circuits and Systems*. 2018-May (2018) 1–5. <https://doi.org/10.1109/ISCAS.2018.8351550>.
- [95] X. Chen, Y. Zhu, H. Zhou, L. Diao, D. Wang, ChineseFoodNet: A large-scale Image Dataset for Chinese Food Recognition, (2017).
- [96] A.M. Rafi, U. Kamal, R. Hoque, A. Abrar, S. Das, R. Laganire, M.K. Hasan, Application of densenet in camera model identification and post-processing detection, *Arxiv.Org*. (2018).
- [97] S. Liang, R. Zhang, D. Liang, T. Song, T. Ai, C. Xia, L. Xia, Y. Wang, Multimodal 3D DenseNet for IDH Genotype Prediction in Gliomas, *Genes*. 9 (2018) 382. <https://doi.org/10.3390/GENES9080382>.
- [98] J. Schmidhuber, S.H. Comput, Long short-term memory, *Neural Comput*. 9 (1997) 1735–1780.
- [99] G. Huang, Y. Zhang, J. Ou, Transfer remaining useful life estimation of bearing using depth-wise separable convolution recurrent network, *Measurement*. 176 (2021) 109090. <https://doi.org/10.1016/J.MEASUREMENT.2021.109090>.
- [100] F. Demir, A. Sengur, A. Ari, K. Siddique, M. Alswaitti, Feature Mapping and Deep Long Short Term Memory Network-Based Efficient Approach for Parkinson’s Disease Diagnosis, *IEEE Access*. 9 (2021) 149456–149464. <https://doi.org/10.1109/ACCESS.2021.3124765>.
- [101] O. Atila, A. Şengür, Attention guided 3D CNN-LSTM model for accurate speech based emotion recognition, *Applied Acoustics*. 182 (2021) 108260. <https://doi.org/10.1016/J.APACOUST.2021.108260>.
- [102] E. Koç, M. Türkoğlu, Forecasting of medical equipment demand and outbreak spreading based on deep long short-term memory network: the COVID-19 pandemic in Turkey, *Signal Image Video Process*. 16 (2022) 613–621. <https://doi.org/10.1007/S11760-020-01847-5/TABLES/6>.
- [103] J. Devlin, M.W. Chang, K. Lee, K. Toutanova, BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, *NAACL HLT 2019- 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies- Proceedings of the Conference*. 1 (2018) 4171–4186. <https://arxiv.org/abs/1810.04805v2> (accessed May 14, 2023).
- [104] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit, N. Houlsby, An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale, *Arxiv.Org*. (2020). <https://arxiv.org/abs/2010.11929v2> (accessed May 14, 2023).
- [105] Z. Liu, Y. Lin, Y. Cao, H. Hu, Y. Wei, Z. Zhang, S. Lin, B. Guo, Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows, *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*. (2021) 10012–10022.
- [106] M. Farahani, M. Gharachorloo, M. Farahani, M. Manthouri, ParsBERT: Transformer-based Model for Persian Language Understanding, *Neural Process Lett*. 53 (2021) 3831–3847. <https://doi.org/10.1007/S11063-021-10528-4/TABLES/9>.

- [107] X. Zhuang, F. Liu, J. Hou, J. Hao, X. Cai, Transformer-Based Interactive Multi-Modal Attention Network for Video Sentiment Detection, *Neural Process Lett.* 54 (2022) 1943–1960. <https://doi.org/10.1007/S11063-021-10713-5/TABLES/8>.
- [108] A. Lin, B. Chen, J. Xu, Z. Zhang, G. Lu, D. Zhang, DS-TransUNet: Dual Swin Transformer U-Net for Medical Image Segmentation, *IEEE Trans Instrum Meas.* 71 (2022). <https://doi.org/10.1109/TIM.2022.3178991>.
- [109] H. Cao, Y. Wang, J. Chen, D. Jiang, X. Zhang, Q. Tian, M. Wang, Swin-Unet: Unet-Like Pure Transformer for Medical Image Segmentation, *Lecture Notes in Computer Science.* 13803 (2023) 205–218. https://doi.org/10.1007/978-3-031-25066-8_9/COVER.
- [110] O. Ronneberger, P. Fischer, T. Brox, U-net: Convolutional networks for biomedical image segmentation, *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics).* 9351 (2015) 234–241. https://doi.org/10.1007/978-3-319-24574-4_28/COVER.
- [111] V. Badrinarayanan, A. Kendall, R. Cipolla, SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, *IEEE Trans Pattern Anal Mach Intell.* 39 (2017) 2481–2495. <https://doi.org/10.1109/TPAMI.2016.2644615>.
- [112] F.I. Diakogiannis, F. Waldner, P. Caccetta, C. Wu, ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data, *ISPRS Journal of Photogrammetry and Remote Sensing.* 162 (2020) 94–114. <https://doi.org/10.1016/J.ISPRSJPRES.2020.01.013>.
- [113] Z. Zhou, M.M. Rahman Siddiquee, N. Tajbakhsh, J. Liang, Unet++: A nested u-net architecture for medical image segmentation, *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics).* 11045 LNCS (2018) 3–11. https://doi.org/10.1007/978-3-030-00889-5_1/COVER.
- [114] O. Oktay, J. Schlemper, L. Le Folgoc, M. Lee, M. Heinrich, K. Misawa, K. Mori, S. McDonagh, N.Y. Hammerla, B. Kainz, B. Glocker, D. Rueckert, Attention U-Net: Learning Where to Look for the Pancreas, (2018). <https://arxiv.org/abs/1804.03999v3> (accessed May 14, 2023).
- [115] H. Üzen, M. Turkoglu, M. Aslan, D. Hanbay, Depth-wise Squeeze and Excitation Block-based Efficient-Unet model for surface defect detection, *Visual Computer.* 39 (2022) 1745–1764. <https://doi.org/10.1007/S00371-022-02442-0/FIGURES/13>.
- [116] H. Uzen, M. Turkoglu, D. Hanbay, Multi-dimensional feature extraction-based deep encoder–decoder network for automatic surface defect detection, *Neural Comput Appl.* 35 (2023) 3263–3282. <https://doi.org/10.1007/S00521-022-07885-Z/TABLES/7>.
- [117] R. Girshick, J. Donahue, T. Darrell, J. Malik, Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR).* (2014) 580–587.
- [118] R. Girshick, Fast R-CNN, *Proceedings of the IEEE International Conference on Computer Vision (ICCV).* (2015) 1440–1448.
- [119] S. Ren, K. He, R. Girshick, J. Sun, Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, *Adv Neural Inf Process Syst.* 28 (2015) 1137–1149. <https://github.com/> (accessed May 14, 2023).

- [120] B. Peng, L. Zhang, D. Zhang, A survey of graph theoretical approaches to image segmentation, *Pattern Recognit.* 46 (2013) 1020–1038. <https://doi.org/10.1016/J.PATCOG.2012.09.015>.
- [121] D.M. Greig, B.T. Porteous, A.H. Seheult, Exact Maximum A Posteriori Estimation for Binary Images, *Journal of the Royal Statistical Society: Series B (Methodological)*. 51 (1989) 271–279. <https://doi.org/10.1111/J.2517-6161.1989.TB01764.X>.
- [122] Y. Boykov, O. Veksler, R. Zabih, Fast approximate energy minimization via graph cuts, *IEEE Trans Pattern Anal Mach Intell.* 23 (2001) 1222–1239. <https://doi.org/10.1109/34.969114>.
- [123] Y. Boykov, G. Funka-Lea, Graph cuts and efficient nd image segmentation., *Int J Comput Vis.* 70 (2006) 109–131. <https://doi.org/10.1007/s11263-006-7934-5>.
- [124] H. Le, S.-W. Jung, K.-S. Choi, S.-J. Ko, T.H. Le, S.-W. Jung, K.-S. Choi, S.-J. Ko, Image segmentation based on modified graph-cut algorithm, *IET.* 46 (2010) 1121–1123. <https://doi.org/10.1049/el.2010.1692>.
- [125] F. Yi, I. Moon, Image segmentation: A survey of graph-cut methods, 2012 International Conference on Systems and Informatics, ICSAI 2012. (2012) 1936–1941. <https://doi.org/10.1109/ICSAI.2012.6223428>.
- [126] C. Cortes, V. Vapnik, Support-vector networks, *Mach Learn.* 20 (1995) 273–297. <https://doi.org/10.1007/BF00994018>.
- [127] M. Türkoğlu, Otomatik Kan Hücrelerinin Tanınması ve Sınıflandırılmasında Değişmez Momentlere Dayalı Görüntü İşleme Yöntemlerinin Kullanılması, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2013.
- [128] A. İmak, Epileptik EEG Sinyallerinin Makine Öğrenmesi Yöntemleri ile Sınıflandırılması, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2019.
- [129] S. Chaplot, L.M. Patnaik, N.R. Jagannathan, Classification of magnetic resonance brain images using wavelets as input to support vector machine and neural network, *Biomed Signal Process Control.* 1 (2006) 86–92. <https://doi.org/10.1016/J.BSPC.2006.05.002>.
- [130] V. Cherkassky, Y. Ma, Practical selection of SVM parameters and noise estimation for SVM regression, *Neural Networks.* 17 (2004) 113–126. [https://doi.org/10.1016/S0893-6080\(03\)00169-2](https://doi.org/10.1016/S0893-6080(03)00169-2).
- [131] I. Ucuz, A.U. Çiçek, A. Ari, O.O. Ozcan, S. Aybüke Sari, Determining the probability of juvenile delinquency by using support vector machines and designing a clinical decision support system, *Med Hypotheses.* 143 (2020) 110118. <https://doi.org/10.1016/J.MEHY.2020.110118>.
- [132] B. Ari, Medikal Veri Setleri İçin Yeni Bir Aşırı Öğrenme Makinesi Otomatik Kodlayıcı Tasarımı, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2022.
- [133] Z.E. Rasjid, R. Setiawan, Performance Comparison and Optimization of Text Document Classification using k-NN and Naïve Bayes Classification Techniques, *Procedia Comput Sci.* 116 (2017) 107–112. <https://doi.org/10.1016/J.PROCS.2017.10.017>.
- [134] M. Ala'raj, M. Majdalawieh, M.F. Abbod, Improving binary classification using filtering based on k-NN proximity graphs, *J Big Data.* 7 (2020) 1–18. <https://doi.org/10.1186/S40537-020-00297-7/TABLES/7>.

- [135] A. Sharmila, P. Geethanjali, DWT Based Detection of Epileptic Seizure from EEG Signals Using Naive Bayes and k-NN Classifiers, *IEEE Access*. 4 (2016) 7716–7727. <https://doi.org/10.1109/ACCESS.2016.2585661>.
- [136] G. Doğan, B. Ergen, A new mobile convolutional neural network-based approach for pixel-wise road surface crack detection, *Measurement*. 195 (2022) 111119. <https://doi.org/10.1016/J.MEASUREMENT.2022.111119>.
- [137] R. Kumar, A. Indrayan, Receiver operating characteristic (ROC) curve for medical researchers, *Indian Pediatr.* 48 (2011) 277–287. <https://doi.org/10.1007/S13312-011-0055-4/METRICS>.
- [138] H. Touvron, M. Cord, M. Douze, F. Massa, A. Sablayrolles, H. Jegou, Training data-efficient image transformers & distillation through attention, *Proceedings of the 38th International Conference on Machine Learning*. 139 (2021) 10347–10357.
- [139] H. Zhao, J. Shi, X. Qi, X. Wang, J. Jia, Pyramid Scene Parsing Network, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. (2017) 2881–2890.
- [140] A. Chaurasia, E. Culurciello, LinkNet: Exploiting encoder representations for efficient semantic segmentation, *2017 IEEE Visual Communications and Image Processing, VCIP 2017*. 2018-January (2018) 1–4. <https://doi.org/10.1109/VCIP.2017.8305148>.
- [141] S. Seferbekov, V. Iglovikov, A. Buslaev, A. Shvets, Feature Pyramid Network for Multi-Class Land Segmentation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*. (2018) 272–275.
- [142] Python, Albumentations, View on GitHub. (2022). <https://albumentations.ai/> (accessed October 20, 2022).
- [143] M. Mubashar, H. Ali, C. Grönlund, S. Azmat, R2U++: a multiscale recurrent residual U-Net with dense skip connections for medical image segmentation, *Neural Comput Appl.* 34 (2022) 17723–17739. <https://doi.org/10.1007/S00521-022-07419-7/FIGURES/13>.
- [144] R. Azad, M. Asadi-Aghbolaghi, M. Fathy, S. Escalera, Bi-Directional ConvLSTM U-Net with Densley Connected Convolutions, (2019) 0–0. <https://doi.org/10.48550/arXiv.1909.00166> (accessed May 20, 2023).
- [145] D. Jha, P.H. Smedsrud, M.A. Riegler, D. Johansen, T. De Lange, P. Halvorsen, H.D. Johansen, ResUNet++: An Advanced Architecture for Medical Image Segmentation, *Proceedings- 2019 IEEE International Symposium on Multimedia, ISM 2019*. (2019) 225–230. <https://doi.org/10.1109/ISM46123.2019.00049>.

ÖZGEÇMİŞ

Andaç İMAK

[REDACTED]

[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]

[REDACTED]

[REDACTED] [REDACTED]
[REDACTED] [REDACTED]

[REDACTED]

[REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED]
[REDACTED]
[REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED]
[REDACTED]
[REDACTED]
[REDACTED] [REDACTED]
[REDACTED]
[REDACTED] [REDACTED]

[REDACTED]

[REDACTED] [REDACTED]

AKADEMİK FAALİYETLER

Makaleler:

1. A. Imak, A. Çelebi, M. Türkoğlu, A. Şengür, Dental Material Detection based on Faster Regional Convolutional Neural Networks and Shape Features, *Neural Process Lett.* 54 (2022) 2107–2126.
2. A. Imak, A. Celebi, K. Siddique, M. Turkoglu, A. Sengur, I. Salam, Dental Caries Detection Using Score-Based Multi-Input Deep Convolutional Neural Network, *IEEE Access.* 10 (2022) 18320–18329.
3. A. Imak, A. Çelebi, O. Polat, M. Türkoğlu, A. Şengür, ResMIBCU-Net: an encoder–decoder network with residual blocks, modified inverted residual block, and bi-directional ConvLSTM for impacted tooth segmentation in panoramic X-ray images, *Oral Radiol.* 1 (2023) 1–15.
4. A. Çelebi, A. Imak, H. Üzen, Ü. Budak, M. Türkoğlu, D. Hanbay, A. Şengür, Maxillary Sinus Detection on Cone Beam Computed Tomography Images using ResNet and Swin Transformer-based UNet, *Oral Surg Oral Med Oral Pathol Oral Radiol.* (2023).

Bildiriler:

1. A. İmak,O. F. Alçin, M. C. İnce, Epileptik EEG Sinyallerinin Aşırı Öğrenme Makineleri Kullanılarak Tespiti, 2017 İmeset International Conference, Bitlis, (2017), (Tam Metin Bildiri).
2. A. İmak,O. F. Alçin, M. C. İnce, Tekrarlılık Ölçüm Analizi ve Aşırı Öğrenme Makinesi Tabanlı Epileptik EEG Sinyallerinin Sınıflandırılması, İets International Conference, Batman, (2018), (Tam Metin Bildiri).
3. A. İmak,O. F. Alçin, M. C. İnce, Çoklu Dalgacık Dönüşümü ve Tekrarlılık Ölçüm Analizi Yöntemleri Kullanılarak Epileptik EEG Sinyallerinin Saptanması, 4th International Energy Engineering Congress (UEMK 2019), Gaziantep, (2019), (Tam Metin Bildiri).

Projeler:

1. Tübitak projesi, “Kuluçka Evresindeki Yumurtalar ile Ticari Yumurtaların Görüntü İşleme Yöntemleri ile Sağlamlık Tespiti”, Bitiş Tarihi: 30.09.2019
2. KOSGEB tarafından desteklenen proje, “Oral Radyolojik Görüntüleme Tekniklerinde Yapay Zeka Tabanlı Uzman Sistem Tasarımı”, Bitiş Tarihi: 11.03.2021