



**DİŐ YAPISININ VE ÖZELLİKLERİNİN  
BELİRLENMESİNDE PANORAMİK  
RADYOGRAFİ GÖRÜNTÜLERİNİN YAPAY  
ÖĞRENME YÖNTEMLERİ İLE ANALİZİ**

**2023  
DOKTORA TEZİ  
BİLGİSAYAR MÜHENDİSLİĐİ**

**Ahmet KARAOĐLU**

**Tez Danışmanı  
Doç. Dr. Caner ÖZCAN**

**DİŐ YAPISININ VE ÖZELLİKLERİNİN BELİRLENMESİNDE  
PANORAMİK RADYOGRAFİ GÖRÜNTÜLERİNİN YAPAY ÖĞRENME  
YÖNTEMLERİ İLE ANALİZİ**

**Ahmet KARAOĐLU**

**Tez Danışmanı  
Doç. Dr. Caner ÖZCAN**

**T.C.  
Karabük Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalında  
Doktora Tezi  
Olarak Hazırlanmıştır**

**KARABÜK  
Mart 2023**

Ahmet KARAOĞLU tarafından hazırlanan “DİŞ YAPISININ VE ÖZELLİKLERİNİN BELİRLENMESİNDE PANORAMİK RADYOĞRAFİ GÖRÜNTÜLERİNİN YAPAY ÖĞRENME YÖNTEMLERİ İLE ANALİZİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Doç. Dr. Caner ÖZCAN .....

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 17/03/2023

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. İlker TÜRKER (KBÜ) .....

Üye : Doç. Dr. Caner ÖZCAN (KBÜ) .....

Üye : Dr. Öğr. Üyesi Eftal ŞEHİRLİ (KBÜ) .....

Üye : Doç. Dr. Abdullah ELEN (BANÜ)

ONLINE

Üye : Dr. Öğr. Üyesi Ahmet ALBAYRAK (DÜ)

ONLINE

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Prof. Dr. Müslüm KUZU .....

Lisansüstü Eğitim Enstitüsü Müdürü

*“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”*

Ahmet KARAOĞLU

## ÖZET

Doktora Tezi

### DİŞ YAPISININ VE ÖZELLİKLERİNİN BELİRLENMESİNDE PANORAMİK RADYOGRAFİ GÖRÜNTÜLERİNİN YAPAY ÖĞRENME YÖNTEMLERİ İLE ANALİZİ

Ahmet KARAOĞLU

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Doç. Dr. Caner ÖZCAN

Mart 2023, 82 sayfa

Bu çalışmada, derin öğrenme ve sezgisel bir yaklaşım kullanılarak panoramik radyografiler üzerinde dişlerin örnek segmentasyonu ve numaralandırılması, dolgu, implant, kanal tedavisi ve protez restorasyonlarının tespit edilmesi sağlanmıştır. Panoramik radyografiler rutin dental muayene sırasında teşhis, planlama ve tedavilerin değerlendirilmesinde sıkça tercih edilen ve uygulaması kolay, maliyeti düşük, ulaşılabilir, nispeten radyasyon dozu az olan görüntüleme yöntemidir. Tek bir radyografi ile hastanın maksillofasial bölgesindeki anatomik yapıları, protezleri, restorasyonları, diş eksiklikleri ve ortodontik tedavisi hakkında bilgiler edinilir. Muayene esnasındaki işlem ağız içi tekniklere göre daha kolay ve hasta için de daha konforludur. Muayene sonucunda elde edilen bilgiler hastaya ekran üzerinde daha kolay ve anlaşılır şekilde izah edilebilir. Bu sebeple, panoramik radyografilerin tanı ve

tedavi süreçlerinde kullanımı önemli ve oldukça yaygındır. Radyograflerin incelenmesi manuel olarak uzman bir kişi tarafından yapıldığı için inceleme işlemi uzun zaman alabilmekte ve oldukça dikkat gerektirmektedir. İnceleme işlemine yorgunluk, yüksek stres düzeyi, ruh hali değişiklikleri, subjektif görüş, deneyimsizlik gibi kişisel durumların da eklenmesi görüntülerin hatalı yorumlanmasına neden olabilmektedir. Bu nedenle inceleme işleminin daha hızlı ve hatasız yapılabilmesi amacıyla derin öğrenme ve sezgisel yaklaşımlı bir yöntem geliştirilmiştir.

Çalışmada kullanılan panoramik radyografler ile ilgili yasal izinler alınmıştır. Panoramik radyografler, isim, yaş, cinsiyet gibi kişisel veriler olmayacak şekilde Karabük Ağız ve Diş Sağlığı Eğitim ve Araştırma Hastanesi arşivinden elde edilmiştir. Dişlerin örnek segmentasyonu, numaralandırılması ve restorasyonların sınıflandırılması için Bölgesel Tabanlı Evrişimli Sinir Ağı (R-CNN) türünden olan ve omurga ağı olarak Artık Ağ-101 (ResNet-101) kullanan Mask R-CNN algoritması kullanılmıştır. Dişlerin numaralandırılması için diş hekimleri tarafından evrensel olarak kullanılan Uluslararası Dişhekimliği Federasyonu (FDI) notasyonu kullanılmıştır. Panoramik radyograflerdeki dişlerin örnek segmentasyonu ve numaralandırılmasında kesinlik, duyarlılık ve F1-puanı sırasıyla %92,21, %91,94, %92,07 olarak hesaplanmıştır. Numaralandırma sonuçları geliştirilen sezgisel bir yaklaşım ile iyileştirilerek kesinlik, duyarlılık ve F1-puanı sırasıyla %92,21, %91,94, %92,07 olarak hesaplanmıştır. Bu sayede, klasik yöntemlerin sezgisel bir yaklaşım ile %4,00 daha başarılı bir performans elde etmesi sağlanmıştır. Dolgu, implant, kanal tedavisi ve protez restorasyonlarının tespitinde ise kesinlik, duyarlılık ve F1-puanı ortalamaları sırasıyla %90,63, %81,33, %85,73 olarak hesaplanmıştır. Deneysel çalışmalar sonucunda ise gerekli şekil, grafik ve çizelgeler ile daha detaylı analiz yapılmış ve elde edilen sonuçlar tartışılmıştır.

**Anahtar Sözcükler :** Derin öğrenme, Mask R-CNN, bilgisayar destekli teşhis, örnek segmentasyonu, panoramik radyografi, diş numaralandırma, diş restorasyon tespiti.

**Bilim Kodu :** 92432.

## **ABSTRACT**

**Ph. D. Thesis**

# **ANALYSIS OF PANORAMIC RADIOGRAPHY IMAGES WITH ARTIFICIAL LEARNING METHODS IN DETERMINATION OF TEETH STRUCTURE AND FEATURES**

**Ahmet KARAOĞLU**

**Karabük University  
Institute of Graduate Programs  
Department of Computer Engineering**

**Thesis Advisor:**

**Assoc. Prof. Dr. Caner OZCAN**

**March 2023, 82 pages**

In this study, a deep learning and heuristic approach was used to perform instance segmentation and numbering of teeth on panoramic radiographs, and to detect filling, implant, root canal and prosthetic restorations. Panoramic radiographs are an easy-to-apply, low-cost, accessible, relatively low-radiation imaging method that is frequently preferred for diagnosis, planning and evaluation of treatments during routine dental examinations. With a single radiograph, information is obtained about the anatomical structures, prostheses, restorations, tooth deficiencies and orthodontic treatment in the patient's maxillofacial region. The procedure during the examination is easier and more comfortable for the patient than the intraoral techniques. The information obtained as a result of the examination can be explained to the patient more easily and clearly on the screen. For this reason, the use of panoramic radiographs in the diagnosis and treatment processes is important and quite common. The addition of personal

factors such as fatigue, high stress levels, mood swings, subjective opinion, inexperience, etc. to the review process can lead to misinterpretation of the images. For this reason, a deep learning and heuristic approach has been developed to make the review process faster and more accurate.

Legal permissions were obtained for the panoramic radiographs used in the study. Panoramic radiographs were obtained from the archive of Karabük Oral and Dental Health Training and Research Hospital without personal data such as name, age, and gender. Mask R-CNN algorithm, which is a Regional Based Convolutional Neural Network (R-CNN) type and uses Residual Network-101 (ResNet-101) as the backbone network, was used for tooth detection, segmentation, numbering and classification of restorations. The International Dental Federation (FDI) notation, which is universally used by dentists, was used for numbering teeth. The precision, sensitivity and F1-score for sample segmentation and numbering of teeth in panoramic radiographs were 92.21%, 91.94%, 92.07%, respectively. The numbering results were improved with a heuristic approach and the precision, sensitivity and F1-score were calculated as 92.21%, 91.94%, 92.07%, respectively. In this way, 4.00% better performance of the conventional methods is achieved with a heuristic approach. For the detection of filling, implant, root canal treatment and prosthetic restorations, the precision, recall and F1-score were 90.63%, 81.33%, 85.73%, respectively. As a result of the experimental studies, a more detailed analysis was made with the necessary figures, graphics and charts and the results were discussed.

**Key Word** : Deep learning, Mask R-CNN, computer-aided diagnosis, instance segmentation, panoramic radiography, teeth numbering, teeth restoration detection.

**Science Code** : 92432.



## TEŞEKKÜR

Bu tez çalışmasının planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren sayın hocam Doç. Dr. Caner ÖZCAN'a sonsuz teşekkürlerimi sunarım.

Ayrıca tez çalışması süresince değerli yorum ve değerlendirmeleri ile desteklerini esirgemeyen sayın hocalarım Doç. Dr. İlker TÜRKER ve Dr. Öğr. Üyesi Eftal ŞEHİRLİ'ye teşekkürlerimi sunarım.

Çalışma süresince her türlü yol gösterici olan, olumlu tavırlarıyla beni cesaretlendiren, her zaman yanımda olan ve yoğun çalışmalarım sırasında bana sabır gösteren ve benden desteğini hiç esirgemeyen sevgili eşim Betül KARAOĞLU ve oğlum Mustafa KARAOĞLU'na teşekkür ederim.

Çalışmam boyunca bana destek olan ve yardımlarını hiç esirgemeyen Öğr. Gör. Buse Yaren TEKİN'e, Dilara ÖZDEMİR'e, Arş. Gör. Elif MEŞECİ'ye ve Süheda ÇİLEK'e teşekkür ederim. Çalışma kapsamında kullanılan veri kümesinin elde edilmesinde büyük rol oynayan sayın Dr. Öğr. Üyesi Âdem PEKİNCE'ye ve sayın Doç. Dr. Yasin YAŞA'ya sonsuz teşekkürlerimi sunarım.

Ek olarak bu tez çalışmamı "2200272" proje numarası ile desteklemeye layık gören Türkiye Bilimsel ve Teknolojik Araştırma Kurumu TÜBİTAK'a teşekkürlerimi sunarım.

Sevgili aileme manevi hiçbir yardımı esirgemediğim yanımda oldukları için tüm kalbimle teşekkür ederim.

## İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER .....	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ .....	xiv
SİMGELER VE KISALTMALAR DİZİNİ .....	xv
BÖLÜM 1 .....	1
GİRİŞ .....	1
BÖLÜM 2 .....	10
EVİRİŞİMLİ SİNİR AĞLARI VE DERİN ÖĞRENME MODELLERİ.....	10
2.1. YAPAY ZEKANIN TARİHÇESİ.....	13
2.2. CNN KAVRAMI .....	16
2.2.1. Giriş Katmanı.....	20
2.2.2. Evrişim Katmanı.....	20
2.2.3. ReLU Katmanı.....	23
2.2.4. Havuzlama Katmanı .....	24
2.2.5. Tam Bağlantılı Katman.....	25
2.2.6. Seyreltme (DropOut) Katmanı .....	25
2.2.7. Sınıflandırma Katmanı.....	26
2.3. EVİRİŞİMLİ SİNİR AĞLARI .....	26
2.3.1. R-CNN.....	26
2.3.2. Fast R-CNN .....	27
2.3.3. Faster R-CNN .....	27
2.3.4. Mask R-CNN.....	28

	<b><u>Sayfa</u></b>
2.4. SEZGİSEL ALGORİTMALAR ve YAKLAŞIMLAR.....	31
2.5. SINIFLANDIRMA MODELLERİNDE BAŞARI KRİTERLERİ .....	32
BÖLÜM 3 .....	35
DENTAL RADYOGRAFİ TÜRLERİ ve PANORAMİK RADYOGRAFİLERİN ETİKETLENMESİ .....	35
3.1. DENTAL RADYOGRAFİLER .....	35
3.1.1. Panoramik Dental Radyografi .....	37
3.1.2. Sefalometrik Dental Radyografi .....	38
3.1.3. Konik Işınlı Bilgisayarlı Tomografi .....	39
3.2. PANORAMİK DENTAL VERİ KÜMESİ VE VERİ ETİKETLEME.....	39
3.2.1. Panoramik Dental Veri Seti .....	41
3.2.2. Panoramik Radyografilerin Etiketlenmesi.....	42
BÖLÜM 4 .....	49
DERİN ÖĞRENME VE SEZGİSEL YAKLAŞIM İLE DENTAL RADYOGRAFİ ANALİZİ.....	49
4.1. DİŞLERİN SEGMENTASYONU VE NUMARALANDIRILMASI .....	49
4.1.1. Veri Setinin Hazırlanması.....	49
4.1.2. Model.....	51
4.1.3. Modelin Eğitimi.....	55
4.2. DİŞ RESTORASYONLARININ TESPİTİ VE SEGMENTASYONU.....	55
4.2.1. Veri Setinin Hazırlanması.....	56
4.2.2. Model.....	57
4.2.3. Modelin Eğitimi.....	58
BÖLÜM 5 .....	59
DENEYSEL ÇALIŞMALAR .....	59
5.1. DİŞLERİN NUMARALANDIRILMASI .....	59
5.2. DİŞLERDEKİ RESTORASYONLARIN TESPİT EDİLMESİ .....	66
BÖLÜM 6 .....	69

	<b><u>Sayfa</u></b>
SONUÇLAR VE ÖNERİLER .....	69
KAYNAKLAR .....	73
ÖZGEÇMİŞ .....	82

## ŞEKİLLER DİZİNİ

### Sayfa

Şekil 2.1. Çok katmanlı perseptron yapay sinir ağları [61].	10
Şekil 2.2. Yapay zekâ alt çalışma konuları.	11
Şekil 2.3. Geleneksel sinir ağları ile derin öğrenmenin karşılaştırılması.	11
Şekil 2.4. Yapay zeka gelişim süreci [62].	12
Şekil 2.5. CNN katmanlarının ve tam bağlantılı katmanlarının diyagramı [71].	17
Şekil 2.6. a) Rakam sınıflandırma görevlerinde iyi şekilde çalışan LeNet-5 ağının mimarisi. b) LeNet-5 ağındaki özelliklerin görselleştirilmesi [72].	19
Şekil 2.7. El yazısı rakam için piksel haritası [75].	21
Şekil 2.8. Tek bir nokta çarpımının hesaplanması [76].	22
Şekil 2.9. Örnek bir evrişim işlemi [76].	22
Şekil 2.10. ReLU Fonksiyonu	23
Şekil 2.11. Maksimum havuzlama katmanı örneği [76].	24
Şekil 2.12. DropOut işlemi. a) Evrişimli Sinir Ağı. b) DropOut uygulanmış hali.	25
Şekil 2.13. R-CNN ile nesne algılama sistemi [4].	26
Şekil 2.14. Örnek segmentasyonu.	29
Şekil 2.15. Örnek segmentasyonu için Mask R-CNN çerçevesi [82].	29
Şekil 2.16. Birleşim üzerinden kesişim.	33
Şekil 3.1. Dental radyografi tipleri. a) Periapikal b) Bitewing c) Panoramik.	36
Şekil 3.2. Örnek bir panoramik röntgen görüntüsü.	37
Şekil 3.3. Örnek bir sefalometrik röntgen görüntüsü.	38
Şekil 3.4. FDI diş numaralandırma sistemi.	41
Şekil 3.5. Radyologların yaptığı diş etiketleme ve numaralandırma örneği.	41
Şekil 3.6. Kullanıcı giriş ekranı.	42
Şekil 3.7. Karşılama ekranı.	44
Şekil 3.8. Proje ekranı.	44
Şekil 3.9. Proje detay ekranı.	45
Şekil 3.10. Veri etiketleme ekranı.	46
Şekil 3.11. Kullanıcı ekranı.	48
Şekil 4.1. K-Katlı çapraz doğrulama.	50
Şekil 4.2. Eğitim setindeki diş etiketlerinin dağılımı.	50

Şekil 4.3. Model eğitiminde kullanılan görüntülerden bazı diş örneklerin maske görüntüleri. ....	51
Şekil 4.4 Sistem mimarisi ve iş hattı. ....	52
Şekil 4.5. Geliştirilen sezgisel yaklaşım. ....	53
Şekil 4.6. Sezgisel yaklaşımın genel akış diyagramı. ....	54
Şekil 4.7. Orijinal radyografik görüntüler ve etiketlenmiş nesnelere. (a) ve (c) radyograflardaki orijinal girdi örnekleri, (b) ve (d) uzmanlar tarafından etiketlenen görüntüler için temel gerçeklik verileri. ....	56
Şekil 4.8. Dişlerin restorasyonlarını tespit eden derin sinir ağı mimarisinin iş akışı. ....	58
Şekil 5.1. KÇD için en iyi tur dönemi kayıp değerleri. (a) Genel kayıp grafiği. (b) Sınıf kaybı grafiği. (c) Maske kaybı grafiği. ....	60
Şekil 5.2. Dişlerin performans metrikleri grafiği. (a) Üst dişlerin performans metrikleri. (b) Alt dişlerin performans metrikleri. ....	62
Şekil 5.3. Diş numaralandırmada sezgisel algoritma sonucunun karmaşıklık matrisi. (a) Üst dişlerin karmaşıklık matrisi. (b) Alt dişlerin karmaşıklık matrisi. ....	62
Şekil 5.4. Tam dişli ve çakışan numaralama olan görüntüde örnek sonuç. (a) Temel gerçeklik. (b) Mask R-CNN Sonucu. (c) Sezgisel algoritma ile iyileştirme. ....	63
Şekil 5.5. Eksik diş ve çakışan numaralama olan görüntüde örnek sonuç. (a) Temel gerçeklik. (b) Mask R-CNN Sonucu. (c) Sezgisel algoritma ile iyileştirme. ....	64
Şekil 5.6. Eksik diş olan ve sıralama hatası olan görüntüde örnek sonuç. (a) Temel gerçeklik. (b) Mask R-CNN sonucu. (c) Sezgisel algoritma ile iyileştirme. ....	65
Şekil 5.7. Restorasyon sınıflandırma sonuçlarının karmaşıklık matrisi. ....	67
Şekil 5.8. Temel gerçek ve segmentasyon sonuçlarıyla görselleştirilen farklı sınıf örnekleri. A ve C, uzmanlar tarafından etiketlenmiş gerçek görüntülerdir. B ve D, modelin tahmin sonuçlarıdır. ....	68

## ÇİZELGELER DİZİNİ

	<b><u>Sayfa</u></b>
Çizelge 2.1. Karmaşıklık matrisi.....	32
Çizelge 5.1. KÇD (K=5) ile verilerin değerlendirilmesi.....	59
Çizelge 5.2. Kullanılan algoritmaların karşılaştırılması. ....	59
Çizelge 5.3. Diş sınıflarına göre performans sonuçları.....	61
Çizelge 5.4. KÇD (K=5) sonuç tablosu ile verilerin değerlendirilmesi. ....	66
Çizelge 5.5. Segmentasyon modelinin performans metrikleri. ....	67
Çizelge 6.1. Panoramik görüntülerde diş numaralandırma çalışmaları. ....	70

## SİMGELER VE KISALTMALAR DİZİNİ

### SİMGELER

- $\mathcal{L}$  : kayıp fonksiyon değeri  
 $\mathcal{L}_{cls}$  : sınıf kayıp değeri  
 $\mathcal{L}_{box}$  : sınıflandırmadan alınan sınırlayıcı kutucuk değeri  
 $\mathcal{L}_{mask}$  : segmentasyondan alınan maske değeri  
 $k$  : toplam sınıf sayısı  
 $m$  : ilgi bölgesi boyutu  
 $y_{ij}$  : oluşan maskedeki bir koordinatın  $i$  ve  $j$  etiketi  
 $\hat{y}_{ij}^k$  :  $k$  sınıfı için tahmin edilen değer  
 $\sum k$  :  $k$  değeri için toplam sembolü



## KISALTMALAR

BG	: Background (Arka plan)
CBCT	: Cone Beam Computed Tomography (Konik Işınlı Bilgisayarlı Tomografi)
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağları)
CPU	: Central Processing Unit (Merkezi İşlem Birimi)
DP	: Doğru Pozitif
CAD	: Computer Aided Diagnosis (Bilgisayar Destekli Teşhis)
CT	: Computed Tomography (Bilgisayarlı Tomografi)
DN	: Doğru Negatif
DNN	: Deep Neural Network (Derin Sinir Ağı)
DVM	: Destek Vektör Makineleri
FCN	: Fully Convolutional Neural Network (Tamamen Evrışimli Sinir Ağı)
FDI	: Fédération Dentaire Internationale (Uluslararası Dişhekimliği Federasyonu)
FPN	: Feature Pyramid Network (Özellik Piramit Ağı)
GPU	: Graphics Processing Unit (Grafik İşlem Birimi)
HTC	: Hybrid Task Cascade (Hibrit Görev Basamağı)
ILSVRC	: ImageNet Large Scale Visual Recognition Challenge (ImageNet Büyük Ölçekli Görsel Tanıma Yarışması)
IOU	: Intersection Over Union (Birleşim Üzerinden Kesişim)
JSON	: JavaScript Object Notation (JavaScript Nesne Notasyonu)
KÇD	: K-Katlı Çapraz Doğrulama
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAP	: Mean Average Precision (Ortalama Genel Hassasiyet)
MÖ	: Makine Öğrenimi
NMS	: Non-Maximum Suppression (Maksimum Olmayan Bastırma)
OPG	: Ortopantomogram
PANet	: Path Aggregation Network (Yol Toplama Ağı)
R-CNN	: Region Based Convolutional Neural Networks (Bölgesel Tabanlı Evrışimli Sinir Ağları)
ReLU	: Rectified Linear Unit (Düzeltilmiş Doğrusal Birim)

ResNeSt	: Split-Attention Networks (Ayrık Dikkat Ağları)
ResNet	: Residual Networks (Artık Ağlar)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
ROI	: Region of Interest (İlgi Bölgesi)
RPN	: Region Proposal Network (Bölge Teklif Ağı)
SPP-net	: Spatial Pyramid Pooling Network (Uzamsal Piramit Havuzu Ağı)
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı

## BÖLÜM 1

### GİRİŞ

Bilgisayar bilimcileri “Bilgisayarlar düşünebilir mi?” sorusuna yanıt vermeye çalıştıkları çalışmalarını sürdürmektedirler. Bu soruyla gündeme gelen yapay zekânın gelişimi 1950’lerde başlamıştır. Yapay zekâ kısaca, “insanların düşünsel olarak uygulamaya çalıştıkları faaliyetlerin otonom olarak gerçekleştirilmesi” olarak tanımlanabilir. Günümüzün en popüler yöntemlerinden biri olan derin öğrenme, makine öğrenmesi ailesine aittir [1].

Güçlü makine öğrenimi modelleri olarak kullanılan Derin Sinir Ağları (DNN), nesne tanıma ve sınıflandırma problemlerine diğer birçok makine öğrenimi tekniğinden farklı bir çözüm sunmaktadır [2]. Birçok yapay zekâ modülü, daha karmaşık modelleri çözme ve öğrenme yeteneğine sahip derin sinir mimarileri kullanılarak geliştirilmektedir. DNN’ler, girdileri derin katmanlardan geçirerek verileri temsil eden özellik çıktılarını verir [3]. Yüksek boyutluluk sorunu nedeniyle, görüntü özelliklerinin öğrenilmesi ve görselleştirilmesi aşamasında çok büyük engeller ortaya çıkmıştır. DNN’lerdeki yüksek boyutluluk ve karmaşık hesaplama problemlerini azaltmak için evrişimli ağlara evrişimli ve havuzlama katmanları eklenmiştir.

Derin öğrenme modelleri radyografik görüntülerde dış sınıflandırması için de kullanılmaktadır. Evrişimli Sinir Ağları’nın (CNN) yedekli öznitelik çıkarma problemi için bölge tabanlı yaklaşımlar ortaya çıkmıştır. Böylece nesne olmayan özelliklere olan ilgi azalmış ve bölgesel temelli bir yaklaşımla nesnelere odaklanılmıştır. Bölgesel Tabanlı Evrişimli Sinir Ağları (R-CNN) [4] algoritmaları ile elde edilmek istenen nesne öznitelikleri çıkarılırken olası bölgeler belirlenmiş ve bu bölgelerde CNN ile sınıflandırma işlemi yapılmıştır. R-CNN yaklaşımı, görüntü üzerinde bölgeleri belirtmek için çok fazla kutu kullandığından, performansı iyileştirmesine rağmen, zaman yönetimi açısından büyük sorunlar yaratmaktadır. Fast R-CNN [5], CNN,

Destek Vektör Makineleri (DVM) ve R-CNN'deki [4] regresörün birleştirilmesiyle önerilmiştir. Bu birleştirme ile yüksek performans elde edilmiş, ancak Fast R-CNN'de kullanılan seçici arama algoritması nedeniyle maliyet yine de yüksek olmuştur. Bölge Teklif Ağı (RPN), maliyeti azaltmak için ilk olarak Faster R-CNN'de [6] kullanılmıştır. Faster R-CNN, nesnelere belirlemede diğer algılama yaklaşımlarından daha iyi performans sunsa da her bir nesneyi ayrı ayrı algılayarak örnek bölütlemeyi tanımlayamamaktadır. Faster R-CNN yapısı üzerine geliştirilen Mask R-CNN [7] nesne tespit kutuları içerisinde nesnelere sınırlarını belirleyecek şekilde çalışır. Diş röntgenlerinde diş sınırlarını işaretlemek için kullanılmıştır.

Diş hekimliği, radyolojik gelişmelere ayak uyduran bir meslektir. Bu gelişmeler, radyolojik görüntülemeyi hasta tanı ve tedavisinde giderek daha önemli hale getirmektedir[8]. İnsanların en sık karşılaştığı sağlık sorunlarından biri olan diş problemlerini tespit ve analiz etmek için diş hekimleri genellikle tüm ağız içini gösteren ve radyasyon miktarı ile radyasyona maruz kalma süresi düşük olan panoramik diş röntgenlerini kullanmaktadır [9]. Diş hekimlerinin ve radyologların tüm çeneyi ve ağız içindeki dişleri görmelerini sağlayan bir çene-yüz görüntüleme tekniği olan panoramik diş röntgenleri, erken teşhis ve tedavi olanağı sağlar. Ağız içi röntgenlerden farklı olarak, panoramik diş röntgenleri, ağızdaki çene ve dişlerin belirli bir alanından ziyade daha geniş alanların görünümünü elde eder [10]. Bu görüntüleme yöntemi, ağzın açılmasını, yutkunma ve nefes almayı sağlayan birçok anatomik bileşenin ayrıntılı görünümünün yanı sıra, diş bölgelerinin dar çeneli ağızlarda bile daha kapsamlı görüntülenmesini sağlar [11]. Hastanın maksillofasiyal bölgesindeki anatomik yapılar, protezler, endodontik tedaviler, restorasyonlar, diş eksiklikleri ve ortodontik tedavi hakkında bilgiler tek bir röntgen ile elde edilir. Panoramik görüntü alma işlemi, hasta açısından diğer ağız içi radyoloji tekniklerine göre daha kolay ve konforludur. Elde edilen bu görüntüler, ekranda daha kolay ve net bir şekilde hastaya anlatılabilir ve ayrıca bu görüntüler ve oluşturulan kayıtlar kimlik tespiti gibi adli vakalarda kullanılabilir. Bu nedenle, ağız ve diş sağlığı polikliniklerinde sıklıkla tercih edilirler. Ancak, uzmanların bir panoramik diş röntgenini yorumlamak için harcadıkları inceleme süresi genellikle uzun ve zahmetlidir [12]. Ayrıca, panoramik

diş röntgenlerinin uzmanlar tarafından yorumlanması sırasında oluşabilecek yüksek artefakt miktarı ve heterojenite, uygun bir yorumlamayı engellemektedir [13,14].

Uzmanların analiz sürelerini azaltarak verimli bir tespit yapılabilmesi için bilgisayar destekli tespit (CAD) sistemlerine ihtiyaç duyulmuştur. CAD yazılımının amaçlarından biri, deneyimsiz veya daha az deneyimli uzmanların yorumlanması zor lezyonları en iyi şekilde teşhis etmelerine yardımcı olmaktır [15]. Diş hekimliğinde maksillofasiyal radyoloji kısıtlı bir sürede çok sayıda görüntüyü yorumlamak ve hızlı bir tedavi planı sunmak durumundadır [16]. Uzmanlar, nihai sonucu gösteren CAD yazılımını etkinleştirerek değerlendirme sırasında işaretlenen nesnelere değerlendirir [17]. Son yıllarda yapay zekâ tabanlı araçlar, en çok tartışılan konulardan biri olan tedavi planlaması, teşhis ve hasta takibi adımlarını kolaylaştırmaktadır. Bu tür araştırmalar, özellikle dentomaksillofasiyal radyolojide, diş tanımlama ve numaralandırma, belirli hastalıkların teşhisi, ortodontistler için sefalometrik analizleri kolaylaştırma, adli diş hekimliğinde tanımlama ile ilgili çalışmalara odaklanmıştır [18]. Yapay zekâ destekli bu tür uygulamalar, uzmanlara karar desteği olarak fayda sağlayacağı gibi diş hekimliği eğitiminde özellikle radyoloji eğitiminde öğrenci ve akademisyenlerin yararlanabilecekleri platformların temelini oluşturacaktır. Özellikle bu araçlar hasta merkezli ve kişiye özel diş sağlığı hizmetlerinin önünü açacaktır. Tüm toplumun ağız sağlığı verilerinin kolayca analiz edilmesini sağlayacaktır [19]. CAD sistemlerine ek olarak geliştirilen otomatik karar destek sistemleri, diş hekimliğinde veri yorumlama ve analizinin yanı sıra tedavi planlama sürecine otomatik çözümler sunar. Yapay zekâ ile geliştirilen otomatik karar sistemleri sayesinde diş hekimlerinin stres ve kaygı gibi yaşadığı olumsuz etkiler de göz ardı edilmektedir [20]. Geliştirilen bu karar destek sistemlerinde tahmin mekanizması uzman yerine yapay sinir ağları tarafından yürütülmektedir.

Büyük veri kümelerini kullanan derin öğrenme algoritmaları olan CNN ve CNN'den türetilen çeşitli sinir ağları ile radyografik görüntüler kullanılarak yapılan çalışmalar segmentasyon, sınıflandırma ve numaralandırma olarak gruplandırılabilir. Amer ve Amer [21], panoramik görüntüler üzerinde yaptıkları çalışma ile otomatik olarak ön işleme, İlgi bölgesi (ROI) çıkarımı ve işlem sonrası şeklinde üç aşamadan oluşan yöntemlerinin, kalıcı dişlerin segmentasyonunda Ortalama Mutlak Hata (MAE)

metriğine göre 110,91 sonucuyla diğer otomatik yöntemlere göre daha iyi sonuç verdiğini göstermişlerdir. Silva vd. [22], yaptıkları çalışmalarında, ısırma ve periapikal (ağız içi) ve panoramik (ağız dışı) olmak üzere X-ray görüntülerine uygulanan bölütleme yöntemlerinin kullanıldığı bazı çalışmaları incelemişlerdir. Çalışma sonucunda incelenen makalelerin çoğunluğunun (%61,0) 1 ile 100 diş röntgeni görüntüsü içeren veri setleri ile çalıştığını tespit etmişlerdir. Ayrıca kendi önerdikleri 1500 görüntüye sahip veri setinin diğer çalışmalara göre önemli bir fark yarattığını tespit etmişlerdir. Wirtz vd. [23], bir sinir ağı ile bağlantılı olarak birleştirilmiş bir modeli kullanan tam otomatik bir yaklaşım ile dişlerin segmentasyonunu gerçekleştirmişlerdir. 14 test görüntüsünden oluşan bir set üzerindeki kesinlik ve hatırlama değerleri, sırasıyla %79,0 ve %82,7 olarak hesaplamışlardır. Karaoğlu vd. [16], diş hekimliği öğrencilerinin eğitimi için yapay zekâ destekli web tabanlı bir radyolojik görüntü analizi ve etiketleme uygulaması olan DentiAssist'i geliştirdikleri çalışmalarında, üç maksillofasiyal radyolog tarafından hassas bir şekilde etiketlenen 649 eğitim ve 279 doğrulama verisi olarak kullanılan panoramik radyografilerde 100 test görüntüsü ile yaptıkları değerlendirmede dişlerin segmentasyonunda %97,75 mAp sonucuna ulaşmışlardır.

Jader vd. [14], Mask R-CNN tabanlı evrişimli sinir ağına dayalı bir segmentasyon sistemi önermişlerdir. Önerdikleri modeli 1500 görüntülü veri seti ile transfer öğrenme stratejileri kullanarak eğiterek, ortalama 32 diş içeren 193 ağız görüntüsü ile doğruluk, F1-puanı, kesinlik, hatırlama ve özgülük değerlerini sırasıyla %98,0, %88,0, %94,0, %84,0 ve %99,0 olarak elde ettiler. Koch vd. [24], dental panoramik radyografilerin semantik segmentasyonu için U-Net [25] mimarisine dayalı bir Tamamen Evrişimli Sinir Ağı (FCN) uyguladılar. Önerilen çalışmanın performansını, 1500 dental panoramik radyograftan oluşan bir veri setinde test ederek 0,934'lük Dice puanına ulaştılar ve bu sonucu geliştirerek 0,936'ya çıkartmışlardır. Muresan vd. [26], 1000 adet etiketli görüntü kullanarak YOLO [27] ile görüntülerin segmentasyonunu %89 doğruluk, %98,00 kesinlik, %91,00 duyarlılık, %93,00 F1-puanı değerlerinde gerçekleştirmişlerdir. Lee vd. [28], modelin eğitim için 846 diş etiketlemesi içeren 30 panoramik radyografi ile doğrulama ve test için 20 panoramik görüntü kullanarak Mask R-CNN modelini kullanan tamamen derin bir öğrenme yöntemi ile diş

segmentasyonunu %87,5 F1-puanı, %85,8 kesinlik, %89,3 duyarlılık ve ortalama birleşim üzerinden kesişim (IOU) değerini %87,7 ile gerçekleştirmişlerdir.

Oktay vd. [29], yaptıkları çalışmada, çoklu sınıflandırmanın yapıldığı AlexNet [30] mimarisinin değiştirilmiş bir versiyonu ile panoramik diş görüntülerindeki dişleri tespit etmeye yönelik bir yöntem sunmuşlardır. Sundukları yöntem ile büyük azı dişleri, küçük azı dişleri, köpek ve kesici dişlerin sınıflandırılmasında sırasıyla %94,32, %91,74, %92,47 doğruluk değerine ulaşmışlardır. Shaheen vd. [31], 186 görüntüden oluşan veri seti ile dişleri segmentlere ayırmak ve sınıflandırmak için bir yapay zekâ çerçevesini 3D U-Net [32] ile oluşturmuşlardır. Diş sınıflandırmasının duyarlılık ve kesinlik değerlerini sırasıyla %98,5 ve %97,9 olarak ölçmüşlerdir. Chung vd. [33], yaptıkları çalışmada, bir uzaysal mesafe düzenleme kaybı tanıtarak noktasal bir diş tespiti gerçekleştiren sinir ağı önermişlerdir. Önerdikleri yöntem sadece mevcut dişleri değil, eksik dişleri de başarılı bir şekilde tespit etmiş ve en iyi performans gösteren yönteme kıyasla diş algılamanın ortalama hassasiyetini %15,71 oranında artırarak son teknoloji yaklaşımlardan daha iyi performans gösterdiğini tespit etmişlerdir. Yapılan diş tanımlaması 99,7% kesinlik ve %97,2 duyarlılık değerine ulaşmıştır. Leite vd. [34], panoramik radyografilerde diş tespiti ve segmentasyonu için yeni yöntemin performansını değerlendirdikleri çalışmalarında, 153 radyografi ile etiketlenen 3576 diş ile eğitilen yapay zekâ destekli yöntem ile diş algılama için %98,9 duyarlılık ve %99,6 kesinlik sonuçlarını elde etmişlerdir. Vinayahalingam vd. [35], dişleri, kuronları, dolguları, kök kanal dolgularını, implantları ve kök kalıntılarını panoramik radyografilerde otomatik olarak tespit eden, segmentlere ayıran ve etiketleyen sistem önermişlerdir. Manuel olarak etiketlenen 2000 panoramik radyografi içinden 1800 adet görüntü kullanarak Resnet-50 ile bir kural tabanlı sezgisel algoritma ve bir kombinatoriyal arama algoritması ile R-CNN maskesine dayalı bir derin öğrenme yaklaşımını eğitmişlerdir. Önerdikleri yöntem ile, sırasıyla algılama, segmentasyon ve etiketleme için %99,3, %95,2 ve %97 f1-puanlarını elde etmişlerdir. Muramatsu vd. [36], derin öğrenme algoritmaları kullanarak panoramik görüntülerdeki dişlerin tespit edilip sınıflandırmasını yaptıkları çalışmalarında duyarlılık değerini dişlerin tespit edilmesinde %96,4, dişlerin sınıflandırılmasında ise %98 olarak hesaplamışlardır.

Tuzoff vd. [37], panoramik radyografilerdeki dişlerin, Faster R-CNN [6] mimarisi ile tespit edilmesini ve VGG-16 [38] CNN'yi kullanarak tespit edilen dişlerin numaralandırılmasının yapılacağı bir sistem önermişlerdir. Önerilen sistemin eğitiminde yetişkinlere ait rastgele seçilmiş 1352 panoramik radyografiden oluşan bir veri seti kullanmışlardır. 222 görüntüden oluşan ayrı bir test seti ile yapılan ölçümlerde diş algılama için duyarlılık ve kesinlik ölçümlerini sırasıyla %99,4 ve %99,45 olarak, diş numaralandırma için duyarlılık ve özgüllük ölçümlerini sırasıyla %98,0 ve %99,94 olarak gerçekleştirmişlerdir. Chen vd. [39], dental periapikal filmlerde dişleri tespit etmek ve numaralandırmak için Faster R-CNN mimarisine dayanan bir yapı önermişlerdir. Faster R-CNN sonuçlarını geliştirmek için “three post-processing techniques” ismini verdikleri tekniği önermişlerdir. Sonuçlar ile hem kesinlik hem de duyarlılık değerlerinin %90,0 değerini aştığını ve tespit edilen kutular ile gerçekler arasındaki IOU ortalama değerinin de %91,0 değerine ulaştığını göstermişlerdir. Kim vd. [40], panoramik diş radyografilerinde periodontal kemik kaybını tespit eden otomatik bir teşhis destek sistemi geliştirmek için derin öğrenmeye dayalı DeNTNet adını verdikleri yöntem önermişler ve bu yöntem ile lezyonları tespit etmenin yanı sıra lezyona karşılık gelen diş numaralarını da tespit etmişlerdir. DeNTNet test setinde %75,0 F1-puanını elde etmişlerdir. Kim vd. [41], bir panoramik radyografi görüntüsünde dişleri ve implantları tespit etmek ve numaralandırmak için R-CNN, Tek Çekim Çoklu Kutu Detektörü ve sezgisel yöntemleri birleştiren yeni bir teknik sunmuşlardır. Bu yöntem ile, R-CNN algoritması kullanılarak diş, implant fikstürü ve kron tespitinin IOU eşik değeri 0,5 olacak şekilde ortalama genel hassasiyet (MAP) değerleri sırasıyla %96,7, %45,1 ve %60,9 olarak elde edilmiştir. Bununla birlikte, CNN ve sezgisel yöntemler kullanan diş numaralandırma algoritmasının hassasiyet, özgüllük ve doğruluk ölçümlerini sırasıyla %84,2, %75,5 ve %84,5 olarak elde etmişlerdir. Silva vd. [42], Mask R-CNN, Yol Toplama Ağı (PANet) [43], Hibrit Görev Basamağı (HTC) [44] ve Ayrık Dikkat Ağları (ResNeSt) [45] olmak üzere dört ağ mimarisinin performansını analiz ettiler ve PANet ağ mimarisinin, yaptıkları değerlendirmede en iyi sonuçları segmentasyonda %71,3 ve numaralandırmada %74,0 mAP ile gerçekleştirdiğini ve ayrıca Mask R-CNN ile elde edilen sonuçları %4,9 ve %3,5 puan yükselttiğini belirtmişlerdir. Estai vd. [46], CNN'i kullanarak Ortodontomogram (OPG) görüntülerinde kalıcı dişleri tespit etmek ve sınıflandırmak için otomatik bir algılama sisteminin değerlendirmesini yaptıkları çalışmalarında 18 yaşından büyük



hastalardan toplam 591 dijital OPG toplayarak etiketlemişler ve oluşturulan bu veri seti ile dişlerin otomatik tespiti ve sınıflandırılması için CNN temelli U-Net ile panoramik görüntülerde diş bölgelerinin ön segmentasyonunu veya ROI'leri tespit etmişlerdir. Ardından gelişmiş bir nesne algılama mimarisi olan Faster R-CNN ile, U-Net tarafından belirlenen ROI içindeki her diş tanımlanmıştır. Son olarak VGG-16 mimarisi ile her diş 32 kategoriye ayırmışlar ve bir diş numarası atamışlardır. ROI algılama modülünün IOU değeri %70,0, diş algılama modülü %99,0 duyarlılık ve %99,0 hassasiyet, diş numaralandırma modülü, %98 duyarlılık, hassasiyet ve F1-puanına ulaşmıştır. Bilgir vd. [47], panoramik radyografilerde dişleri tespit etmek ve numaralandırmak için derin bir evrişimli sinir ağı yöntemine dayanan bir yapay zekâ sisteminin tanısallık performansını doğruladıkları çalışmalarında yetişkinlere ait 2482 anonim panoramik radyografi içeren veri setleri ile Faster R-CNN InceptionV2 [48] modelini eğitmişlerdir. Yapılan testlerin hassasiyet, kesinlik ve F1-puanı sırasıyla %95,59, %96,52 ve %96,06 olarak gerçekleşmiştir. Görürgöz vd. [49], periapikal görüntülerdeki dişleri otomatik olarak algılamak ve numaralandırmak için R-CNN başlangıç mimarisine dayalı bir yapay zekâ algoritması tasarlamışlardır. 156 periapikal radyografideki 864 dişten 668'i test veri setinde doğru şekilde numaralandırılarak eğitmiş oldukları modelin sonuçlarını, F1-puanı, kesinlik ve duyarlılık olarak sırasıyla %87,2, %78,12 ve %98,7 olarak ölçmüşlerdir. Kılıç vd. [50], 5-7 yaş aralığındaki çocuk hastadan alınan 421 adet panoramik görüntü üzerinde eğitmiş oldukları Faster R-CNN InceptionV2 modeli ile dişlerin tespiti ve numaralandırılmasında hassasiyet, kesinlik ve F1-puanı değerlerini sırasıyla %98, %95,7 ve %96,8 olarak hesaplamışlardır. Lin vd. [51], yaptıkları çalışmada dişleri CNN kullanarak otomatik olarak dişleri numaralandıran ve dişlerdeki altı farklı durumu tespit edebilen bir sistem önermişlerdir. Önerdikleri sistemin doğruluk değerini diş numaralandırmada %95,62, diş durumunun tespitinde ise %98,33 olarak hesaplamışlardır. Privado vd. [52], panoramik radyografilerde dişlerin numaralandırılmasını Mask R-CNN kullanarak gerçekleştirmiş oldukları çalışmalarında diş numaralandırmada doğruluk değerini %93,83 olarak hesaplamışlardır. Mahdi vd. [53], Faster R-CNN modelini kullanarak, diş adaylarının hem konumsal ilişkisini hem de güven puanını değerlendiren bir aday optimizasyon tekniği kullanarak sonuçlarını daha da geliştirdikleri otomatik bir diş algılama yöntemi önermişlerdir. Önerilen optimizasyon tekniği ile model sonuçlarını ResNet-50 ve ResNet-101 için sırasıyla %97,40 ve %98,10 mAP değerlerine

ulařtırmıřlardır. Akkaya vd. [54], pediatrik panoramik radyografilerde otomatik diř tespiti ve numaralandırma için YOLO V4 modelini kullanmıřlardır. Önerdikleri model, mAP performans metriğinde %92,22 sonuç elde etmiřtir. Chandrashekar vd. [55], diř segmentasyonu ile numaralandırma iřlemi için, Mask R-CNN ile Faster R-CNN modellerini birleřtirerek yeni bir yöntem önermiřlerdir. Önerdikleri yöntem diř numaralandırmada %98,44 mAP deęerine ulařmıřtır. Tekin vd. [56], Mask R-CNN'nin, örnek segmentasyonu iřlevi gören ve her ROI birimine uygulandıęında pikselden piksele segmentasyon maskesini tahmin eden bir yöntemini kullanarak bitewing görüntülerindeki diřlerin %100 kesinlik ve %97,49 mAP deęerlerinde segmentasyonunu, %94,35 kesinlik ve %91,51 mAP deęerlerinde ise FDI sisteminde göre diř numaralandırmasını gerekleřtirmiřlerdir. Kullandıkları Mask R-CNN yönteminin performansını son teknoloji yöntemlerle karřılařtırarak kanıtlamıřlardır. Karaoęlu vd. [57], 2702 adet panoramik radyografisi kullandıkları alıřmalarında, Mask R-CNN algoritmasının diř tespiti ve numaralandırma sonuçlarını, geliřtirdikleri sezgisel yaklařım ile yaklařık %4,0 oranında arttırarak kesinlik, duyarlılık ve F1-puanı metriklerinde sırasıyla %92,49, %96,08, %95,65 sonuçlarını elde etmiřlerdir.

Bu tez alıřması, beř ana bölümden oluřmaktadır. Birinci bölümde derin öęrenme modelleri kullanılarak radyografik görüntülerde diř sınıflandırması, numaralandırılması ve restorasyonu ile ilgili alıřmaları içeren literatür arařtırması yer almaktadır. İkinci bölümde, Evriřimli Sinir Aęları ve derin öęrenme modelleri hakkında ayrıntılı bilgiler verilmektedir. Üüncü bölümde, diř görüntüleme yöntemleri, veri etiketleme ile ilgili bilgiler yer almaktadır. Dördüncü bölümde, panoramik diř röntgenlerinin derin öęrenme tabanlı yöntemler ile analizi ve alıřmada kullanılan Mask R-CNN modeli ve geliřtirilen sezgisel yaklařım hakkında ayrıntılı bilgiler verilmektedir. Beřinci bölümde deneysel alıřmalar yer almaktadır. Sunulan yöntem ile iki ayrı alıřma gerekleřtirilmiřtir. Birinci alıřmada, Mask R-CNN ve sezgisel yaklařımlı yöntem ile, FDI sistemine göre panoramik diř röntgenleri üzerinde diřler arka plandan ayıralak numaralandırılmıřtır. Derin öęrenme algoritmasının eęitimi için gerekli olan görüntülerin etiketlemesi, oluřturulan web tabanlı etiketleme yazılımını DentiAssist [58] kullanılarak iki dental radyolog tarafından manuel olarak gerekleřtirilmiřtir.

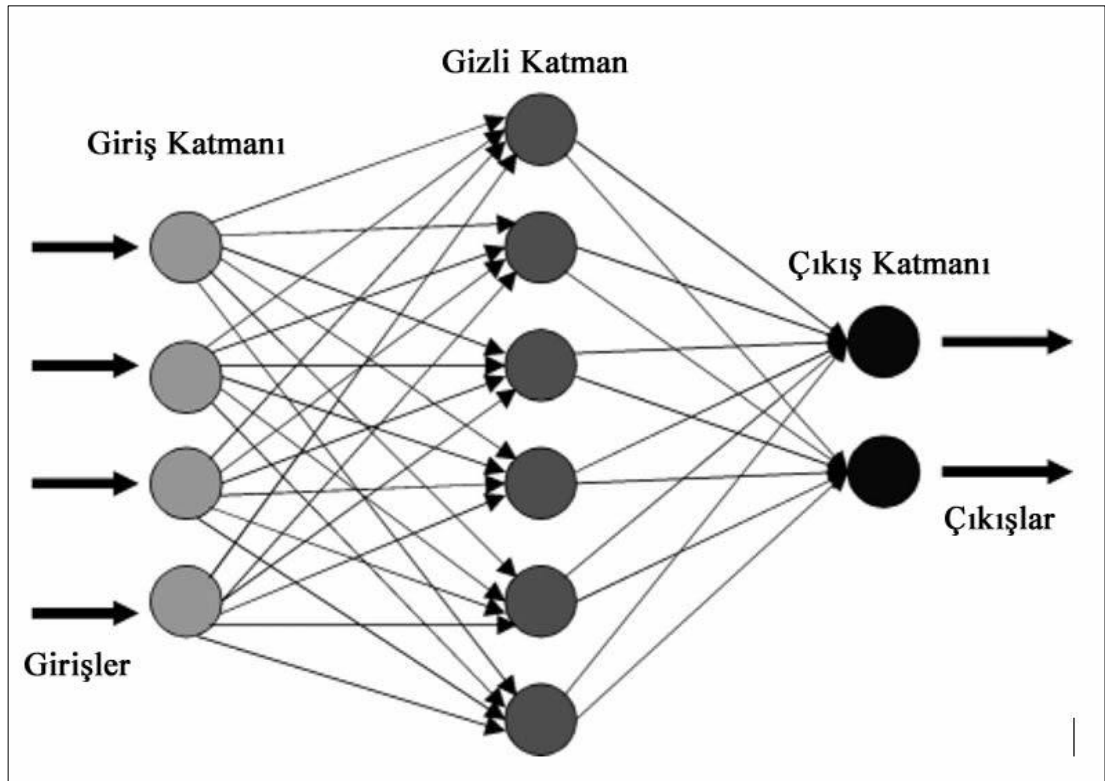
İkinci çalışmada, her bir diş restorasyon sınıfını bölütleme görevi, her sınıf için DentiAssist kullanılarak iki dental radyolog tarafından manuel olarak oluşturulan etiketlerle gerçekleştirilmiştir. Diş restorasyonlarını panoramik diş röntgenlerinde tespit edebilmek ve yapay zekâ destekli bir sistem oluşturabilmek için görüntü üzerinde koordinatların elde edilebildiği bölgesel bir yaklaşım izlenmiştir. Çalışmada, Mask R-CNN'nin derin artık ağ omurgasını kullanarak 800 epok eğitilmiştir.

Altıncı bölümde yapılan çalışmalar ile elde edilen sonuçlar karşılaştırmalı olarak yorumlanmaktadır. Gelecekte yapılabilecek çalışmalar için öneriler de bu bölümde yer almaktadır.

## BÖLÜM 2

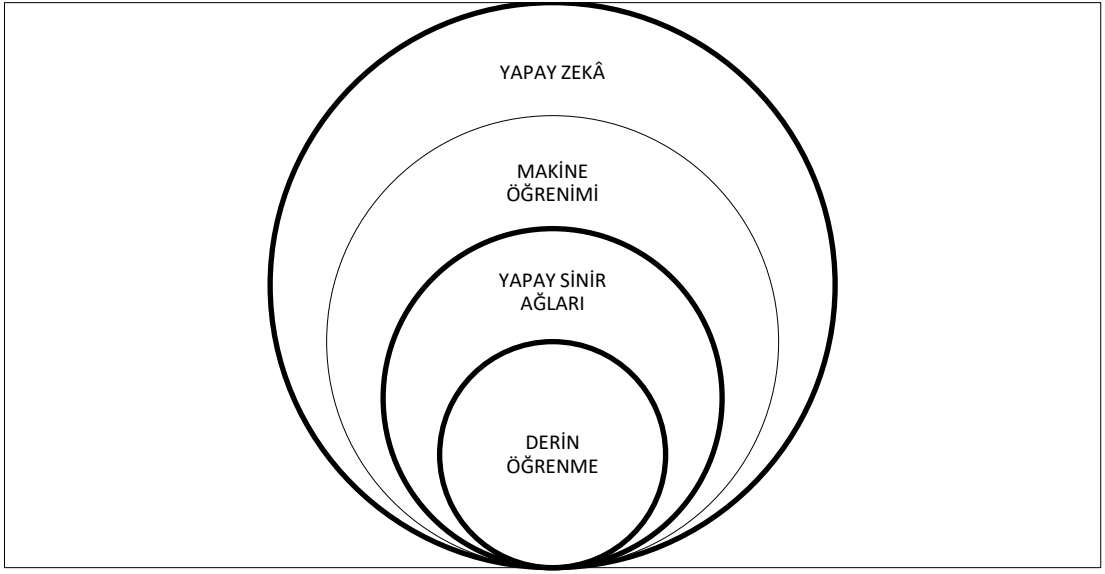
### EVRIŞİMLİ SİNİR AĞLARI VE DERİN ÖĞRENME MODELLERİ

Yapay zekâ, minimum insan müdahalesi ile akıllı davranışı modellemek için bir bilgisayarın kullanılmasını ifade eden genel bir terimdir. Yapay zekânın genellikle robotların icadıyla başladığı kabul edilir. Yakın döneme baktığımız zaman, yapay zekâ kavramı için ilk dönüm noktası McCulloch ve Pitts tarafından 1943 yılında basit ikili eşik fonksiyonlarını kullanarak ilk yapay nöronu geliştirilmesi olmuştur [59]. Bir sonraki önemli dönüm noktası ise, psikolog Frank Rosenblatt'ın 1958 yılında perseptronu pratik bir model olarak geliştirmesidir [60]. Temel perseptron ağının birçok çeşidi önerilmiştir, ancak en popüler model Şekil 2.1'de gösterilen çok katmanlı perseptron olmuştur.



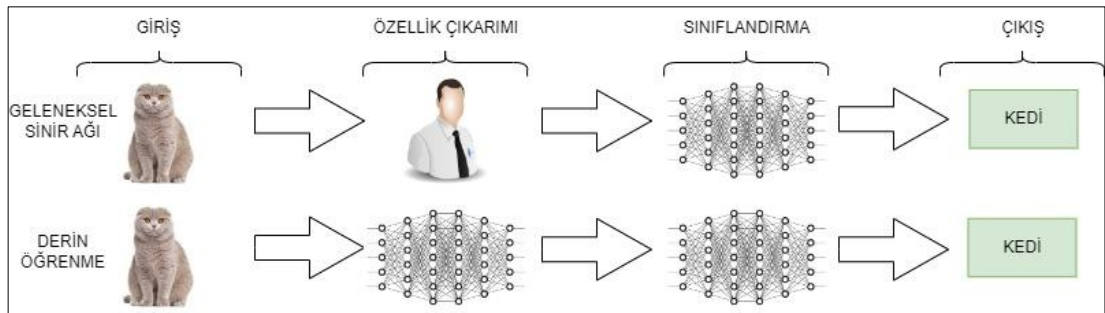
Şekil 2.1. Çok katmanlı perseptron yapay sinir ağları [61].

Bu ağlar, tipik olarak bir giriş katmanı, bir veya daha fazla orta veya gizli katman ve her biri diğer katmana tamamen bağlı olan bir çıktı katmanı olan nöron katmanlarından oluşur. Nöronlar bağlantılarla bağlanır ve her bağlantının kendisiyle ilişkili sayısal bir ağırlığı vardır. Bu ağırlıkların tekrarlanan ayarlamaları yoluyla bir sinir ağı oluşur [61]. Şekil 2.2’de gösterildiği gibi yaşanan gelişmeler neticesinde yapay zekâ kavramı genişlemiş ve alt çalışma konuları ortaya çıkmıştır.



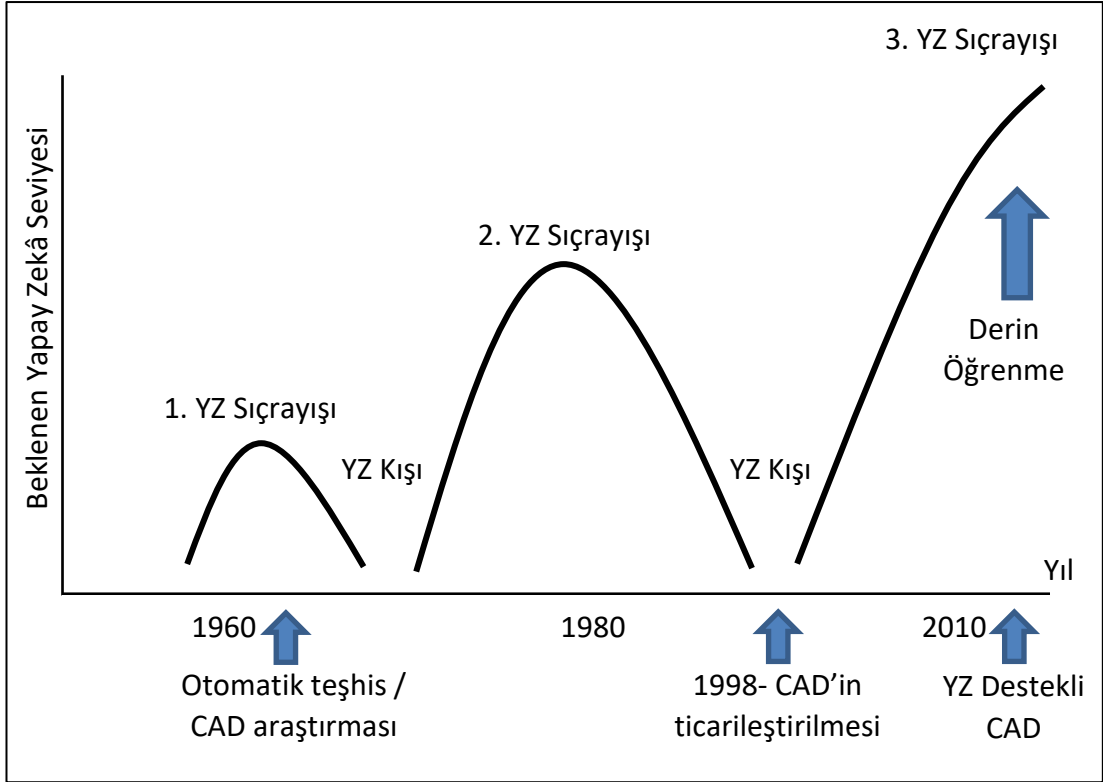
Şekil 2.2. Yapay zekâ alt çalışma konuları.

Günümüzün popüler yapay zekâ çalışma alanlarından biri olan derin öğrenme ise, yapay zekâda önemli bir ilerlemeye yol açmıştır. Şekil 2.3’te gösterildiği gibi belirli sayıda özellik kullanan ve insan girdisi gerektiren geleneksel sinir ağlarının aksine, derin öğrenme verileri kendi başına sınıflandırmak için eğitilebilmektedir.



Şekil 2.3. Geleneksel sinir ağları ile derin öğrenmenin karşılaştırılması.

Derin öğrenme ilk olarak 1950’lerde çalışılmış olmasına rağmen, bazı alanlara uyarlanması “aşırı öğrenme” sorununa sebep olmuştur. Derin öğrenme belirli bir veri kümesine fazla odaklandığında ve yetersiz bilgi işlem kapasitesi ile eğitim verisi eksikliğinin bir sonucu olabilecek yeni veri kümelerini doğru bir şekilde işleyemediğinde aşırı öğrenme oluşur. Bu sınırlamalar, 2000’li yıllarda daha büyük veri kümelerinin mevcudiyeti ve önemli ölçüde geliştirilmiş bilgi işlem gücü ile aşılmıştır. Şekil 2.4’te görüldüğü gibi yapay zekâ üçüncü sıçrayışını derin öğrenme ile yaşamaktadır [62].



Şekil 2.4. Yapay zeka gelişim süreci [62].

Derin öğrenme terimi, yapay zekâ alanında önemli çalışmaları olan Toronto Üniversitesi Fahri Profesörü Geoffrey Hinton'dan gelmektedir. Bunun nedeni, 2006 tarihli makalesinde, derin öğrenme için genel bir terim olarak derin, çok katmanlı bir sinir ağına atıfta bulunmasıdır. 2012'de ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) adlı bir görüntü tanıma yarışmasında, Hinton ve meslektaşları, bir önceki yıla göre kazanan rekorun tanıma hata oranını veya yanlış tanıma oranını

%40 oranında azaltmak için bir derin öğrenme yöntemi kullanmışlardır. Bu sayede bir önceki hata sonucu %25,7'den %15,3'e geliştirildi ve bu da tarihi bir gelişme oldu. Hinton, 2016 sonbaharında uluslararası bir konferansta “derin öğrenmenin beş yıl içinde radyoloji uzmanı seviyesine ulaşacağını” söyleyerek derin öğrenmenin geleceğinin olduğu vurgusunu da yapmıştır [62].

Yüzeysel makine öğreniminden farklı olarak derin öğrenme, özellik çıkarma ve dönüştürme için bir dizi doğrusal olmayan işlem birimi katmanı kullanır. Bilgisayarların, daha yüksek seviye özelliklerin daha düşük seviye özelliklerden türetildiği, verilerin hiyerarşik bir temsilinden öğrenmesine olanak tanır. Örneğin, bir görüntü verildiğinde, derin bir sinir ağı bu görüntünün farklı özelliklerini her bir gizli katmanda çıkarabilir. Bu görüntünün pikselleri girdi olarak verildiğinde, komşu piksellerin renkleri veya parlaklıkları karşılaştırılarak birinci katmanda kenarlar tanımlanabilir. Ardından, ikinci gizli katman, kenarların açıklamasını kullanarak köşeleri ve konturları algılayabilir. Bundan sonra, belirli kontur ve köşe koleksiyonları aranarak belirli nesnelerin parçaları bulunabilir. Son olarak, giriş görüntüsündeki nesnelere tanınabilir. Derin mimarilerin çok sayıda çeşidi vardır ve farklı veri kaynaklarını temsil etmek için farklı mimariler kullanılabilir. Örneğin, CNN, görüntü tanıma için en popüler mimaridir ve Tekrarlayan Sinir Ağı (RNN), el yazısı veya konuşma tanıma gibi sıralı görevlere daha uygundur [63].

## 2.1. YAPAY ZEKANIN TARİHÇESİ

Bilgisayarlar sadece yaklaşık yetmiş yıldır varken, insanlar yüzyıllardır makinelerin insan beyniyle aynı bilişsel süreçleri tamamlayabileceği fikriyle çalışmalar gerçekleştirmektedirler. Robotların ilk fikirleri ve çizimleri, Yunan mitolojisine ve Çin ve Mısır kültürüne kadar uzandığı düşünülmektedir [64].

- Antik çağdaki birçok efsane, insan benzeri eserleri tasvir etti. Örneğin, demirci Hephaestus'u içeren mitler, mekanik olarak çalışan hizmetçileri tasvir ediyordu. “Robot” terimi yüzyıllarca icat edilmeyecek olsa da bu fikrin ilk kavramsallaştırmalarından biri olarak kabul edilebilir.

- 13. yüzyılda MS 1206’da mucit El-Cezeri tarafından icat edilen ilk insansı robot geliştirildi.
- 15. yüzyılda Johannes Gutenberg, matbaayı MS 1440 civarında icat etti ve Leonardo da Vinci, 1495’te bir “robot” tasarladı.
- 16. yüzyılda ilk ölçüm makinesi olan saat icat edildi.
- 17. yüzyılda dijital ve aritmetik hesaplamalar yapabilen makineler BIYZSe Pascal ve Sir Samuel Morland tarafından icat edildi ve Gottfried Wilhelm Leibniz tarafından geliştirildi.
- 19. yüzyılda ilk programlanabilir makine olan dokuma tezgâhı Joseph-Marie Jacquard tarafından icat edildi.
- 20. yüzyılda;
  - (1912) Elektromıknatıslarla çalışan satranç makinesi Torres y Quevedo tarafından icat edildi.
  - (1920) “Robot” terimi ilk defa Çek yazar Karel Čapek’in yazdığı “Rossum’un Evrensel Robotları” isimli oyununda kullanıldı.
  - (1939) Westinghouse Electricat, 1939 Dünya Fuarı’nda “mekanik bir adam” adını verdikleri cihazlarını tanıttı.
  - (1945) “Sezgisel düşünme” kavramı George Polya tarafından yazılan “How to Solve It” adlı kitabında tartışılır ve yapay zekanın arkasındaki bilimi büyük ölçüde etkilediği söylenir.
  - (1950) Robotiğin üç yasası Amerikalı yazar Isaac Asimov tarafından yayınlandı.
  - (1956) “Yapay zekâ” terimi John McCarthy tarafından ortaya atıldı.
  - (1956) İlk işlevsel YZ programı Allen Newell, JC Shaw ve Herbert Simon tarafından yazıldı.
  - (1957) IBM’den Arthur Samuel, dama öğrenebilen ve bir dünya şampiyonuna meydan okuyabilen ilk oyun oynama programını yazdı.
  - (1962) İlk endüstriyel robot şirketi olan Unimation kuruldu.
  - (1963-1971) Bilgisayarların aynı tür analogileri, problemleri çözebildiği ve dili anlayabildiği birçok bilim adamı tarafından keşfedildi.
  - (1973) İlk cep telefonu görüşmesi yapıldı.
  - (1976) Apple 1 piyasaya çıktı ve 666,66 dolara satıldı.



- (1980) LISP makineleri resmi olarak piyasaya çıktı.
  - (1981) Danny Hill bağlantı makinesini tasarladı.
  - (1989) World Wide Web oluşturuldu.
  - (1992) IBM, ilk “akıllı telefon” olan Simon Personal Communicator’ı geliştirdi.
  - (1997) IBM tarafından geliştirilen Deep Blue, Dünya satranç şampiyonu olan Garry Kasparov ile girdiği satranç karşılaşmasını kazandı.
- 21. Yüzyılda
    - (2006) Derin öğrenmeyi ilk defa inceleyen Çoklu Öğrenme kavramını Geoffrey Hinton sundu.
    - (2007) Apple, iPhone’u piyasaya sürdü.
    - (2010) Apple, ses tanıma ve yapay zekâ teknolojisini kullanan kişisel asistanı Siri’yi sundu.
    - (2011) Hızlı cevap verebilen ve iki dil şampiyonunu yenen Watson bilgisayarını IBM tarafından geliştirildi.
    - (2014) Microsoft, Apple’ın Siri’sinin doğrudan rakibi olan Cortana’yı tanıttı
    - (2015) Amazon, kişisel asistanı Alexa ile Echo’yu yayınladı.
    - (2015) Harvard’daki Future Society, yapay zekanın araştırılması, geliştirilmesi ve etik kullanımına adanmış AI Girişimi’ni başlattı.
    - (2016) Google DeepMind tarafından geliştirilen AlphaGO, Lee Sedol ile yaptığı go müsabakasını 4-1 sonucuyla kazanarak dikkatleri üzerine çekmeyi başardı.
    - (2019), OpenAI’nin geliştirdiği ve 1.5 milyar parametreye sahip olan GPT-2 yayınlandı.
    - (2020) Alphafold: 50 yıla yakın bir süredir çözümü üzerinde çalışılan protein katlanma problemi, 175 milyar parametreye sahip olan GPT-3 ile çözümlenerek önemli bir ilerleme sağlandı.
    - (2021) Open AI tarafından geliştirilmiş olan DALL-E yazı ile tarif edilmiş resimleri üretebilme özelliğine sahip olarak dikkat çekti.

- (2022) Open AI tarafından geliştirilmiş olan GPT (Generative Pre-Trained Transformer) ailesinin en yeni üyesi olan ve Türkçe ile birlikte birçok dilde sorular sorulabilen, insan benzeri metinler üretebilen, insan dilini anlayabilen ChatGPT tanıtıldı.

## 2.2. CNN KAVRAMI

CNN, insan beyninin birbirine bağlı nöronlarının davranışını simüle eden görüntü işlemeye uygulanan bir tür derin öğrenme algoritmasıdır. Bir CNN, kalıpları tanımak ve belirli filtreler oluşturmak için bir giriş görüntüsünü analiz eden birkaç katmandan oluşur. Nihai sonuç, tamamen bağlı katmanlar tarafından tüm özelliklerin birleştirilmesiyle üretilir. LeNet [65], AlexNet [30], GoogLeNet [66], VGGNet [38] ve ResNet [67] dahil olmak üzere çeşitli CNN modelleri mevcuttur [68].

**LeNet:** Evrişimli ağların kullanımları 1990'larda yaygındı. Bunlardan en bilineni, el yazısı rakamları, posta kodlarını vb. incelemek için kullanılan LeNet yapısıdır [65].

**AlexNet:** Bilgisayarlı görüde evrişimli ağları geliştiren ana çalışma AlexNet'tir. AlexNet, imagenet büyük ölçekli görsel tanıma yarışmasına 2012 yılında katılmıştır. ILSVRC [69] yarışması, nesne algılama ve görüntü sınıflandırma tekniklerini inceler ve ayrıca büyük ölçekte bilgisayar görüşünün ilerlemesini ölçer. AlexNet sınıflandırma hata oranı %15,3 ile bu yarışmada en yüksek dereceyi sağladı [30].

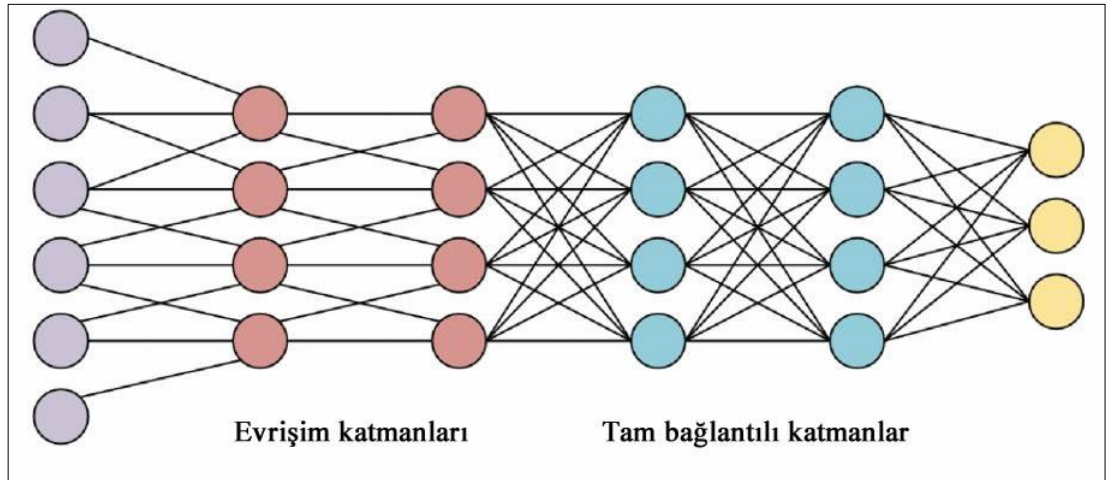
**GoogLeNet:** GoogLeNet evrişimli ağı, ILSVRC 2014 yarışmasını kazandı. Temel faydası, sistemdeki parametre miktarını büyük ölçüde azaltan bir başlangıç modülünün geliştirilmesiydi. Bu modül 60 milyon olan AlexNet'in aksine GoogLeNet'de sadece 4 milyon olarak azaltılmıştır. Ayrıca, bu yöntem, evrişimli ağın en yüksek noktasında tam olarak bağlı katmanlar yerine ortalama havuzlamayı kullanır ve pek bir fark yaratmıyor gibi görünen birçok parametreden vazgeçerek performans artışı sağlamıştır [66].

**VGGNet:** Amacı sistemin derinliğinin iyi yürütme için temel bir parça olduğunu göstermektir. En iyi sistemleri, on altı evrişimli ve tamamen bağlantılıdır. VGGNet'in

bazı dezavantajları vardır. Değerlendirmesi çok maliyetlidir ve ayrıca önemli ölçüde daha fazla bellek ve daha fazla parametre (140 milyon) kullanır [38].

**ResNet:** ResNet, ILSVRC 2015'in galibi olmuştur. Olağanüstü atlama ilişkilendirmelerini ve toplu normalleştirme'nin önemli ölçüde kullanıldığını göstermektedir. Tasarım ayrıca sistemin sonuna doğru tamamen ilişkili katmanlardan yoksundur [67].

CNN, son yıllarda örüntü tanıma ile ilgili görüntü işlemeden ses tanıma kadar çeşitli alanlarda çığır açan sonuçlar elde etmiştir. CNN'lerin en faydalı yönü, Yapay Sinir Ağı (YSA) içindeki parametre sayısını azaltmasıdır. Bu başarı hem araştırmacıları hem de geliştiricileri, klasik YSA'larla mümkün olmayan karmaşık görevleri çözmek için daha büyük modellere yönelmeye sevk etmiştir. CNN tarafından çözülen problemlerle ilgili en önemli varsayım, konumsal olarak bağımlı özelliklere sahip olmamasıdır. Yani örneğin bir yüz tanıma uygulamasında yüzlerin görüntülerde nerede bulunduğu dikkat etmeye gerek kalmamaktadır. Tek amaç, verilen görüntülerdeki konumları ne olursa olsun nesnelere tespit etmektir. CNN'in bir diğer önemli yönü, girdi daha derin katmanlara doğru yayıldığında soyut özellikleri de elde etmesidir. Örneğin, görüntü sınıflandırmasında, kenar ilk katmanlarda algılanabilir ve ardından ikinci katmanlarda daha basit şekiller ve nesnelere gibi daha yüksek seviyeli özellikler algılanabilir [70].



Şekil 2.5. CNN katmanlarının ve tam bağlantılı katmanlarının diyagramı [71].

CNN, evrişim yapılarıyla verilerden özellikler çıkarabilen bir tür ileri beslemeli sinir ağıdır. Geleneksel özellik çıkarma yöntemlerinden farklı olarak, CNN'nin özellikleri manuel olarak çıkarması gerekmez. CNN çekirdekleri, çeşitli özelliklere yanıt verebilen farklı alıcıları temsil eder. Aktivasyon fonksiyonları, yalnızca belirli bir eşiği aşan nöral elektrik sinyallerinin bir sonraki nörona iletilebileceği fonksiyonunu ifade eder. Kayıp fonksiyonları ve optimize ediciler, insanların tüm CNN sistemine ne beklediğini öğrenmesini öğretmek için geliştirdikleri yapılardır. Şekil 2.5'teki tam bağlantılı katman ile karşılaştırıldığında, CNN aşağıdaki gibi birçok avantaja sahiptir:



- Yerel bağlantılar: Her bir nöron artık bir önceki katmandaki tüm nöronlara bağlı değildir, yalnızca az sayıda nörona bağlıdır, bu da parametreleri azaltmada ve yakınsamayı hızlandırmada etkilidir.
- Ağırlık paylaşımı: Bir grup bağlantı, parametreleri daha da azaltan aynı ağırlıkları paylaşabilir.
- Altörnekleme boyut küçültme: Bir havuzlama katmanı, yararlı bilgileri korurken veri miktarını azaltabilen bir görüntüyü altörnekleme için görüntü yerel korelasyon ilkesinden yararlanır. Önemsiz özellikleri kaldırarak parametre sayısını da azaltabilir.

Bu üç çekici özellik, CNN'yi derin öğrenme alanındaki en önemli algoritmalarından biri yapar [71].

Literatürde CNN mimarilerinin çok sayıda çeşidi vardır. Bununla birlikte, temel bileşenleri çok benzerdir. Örneğin LeNet [65] mimarisi, evrişimli, havuzlama ve tamamen bağlı katmanlar olmak üzere üç tür katmandan oluşur. Evrişim katmanı, girdilerin özellik temsillerini öğrenmeyi amaçlar.

Şekil 2.6 (a)'da gösterildiği gibi, evrişim katmanı birkaç evrişim çekirdeğinden oluşur. Farklı özellik haritalarını hesaplamak için kullanılır. Spesifik olarak, bir özellik haritasının her bir nöronu, bir önceki katmandaki komşu nöronların bir bölgesine bağlıdır. Böyle bir komşuluk, bir önceki katmanda nöronun alıcı alanı olarak adlandırılır.

Yeni özellik haritası, önce girdiyi öğrenilmiş bir çekirdekle evriştirerek ve ardından evrilmiş sonuçlara eleman bazında doğrusal olmayan bir aktivasyon fonksiyonu uygulayarak elde edilebilir [72].



Şekil 2.6. a) Rakam sınıflandırmada iyi şekilde çalışan LeNet-5 ağının mimarisi. b) LeNet-5 ağındaki özelliklerin görselleştirilmesi [72].

Şekil 2.5'teki CNN'nin temel işlevleri, dört temel alana ayrılabilir:

1. YSA'nın diğer formlarında olduğu gibi, girdi katmanı görüntünün piksel değerlerini tutacaktır.
2. Evrişim katmanı, girdinin yerel bölgelerine bağlı olan nöronların çıktısını, ağırlıkları ile girdi hacmine bağlı bölge arasındaki skaler çarpımı hesaplayarak belirleyecektir. Düzeltilmiş Doğrusal Birim (ReLU), önceki katman tarafından üretilen aktivasyonun çıktısına sigmoid gibi element bazında bir aktivasyon fonksiyonu uygulamayı amaçlar.
3. Havuzlama katmanı, verilen girdinin uzamsal boyutu boyunca basit bir şekilde altörnekleme gerçekleştirecek ve bu aktivasyon içindeki parametre sayısını daha da azaltacaktır.

4. Tamamen bağlantılı katmanlar daha sonra standart YSA'larda bulunan aynı görevleri yerine getirecek ve sınıflandırma için kullanılacak aktivasyonlardan sınıf puanları üretmeye çalışacaktır. Performansı artırmak için bu katmanlar arasında ReLU kullanılması da önerilmektedir.

Bu basit transformasyon yöntemi sayesinde, CNN'ler, sınıflandırma ve regresyon amaçları için sınıf puanları üretmek üzere evrişimli ve aşağı örnekleme tekniklerini kullanarak orijinal giriş katmanını katman katman dönüştürebilir [73].

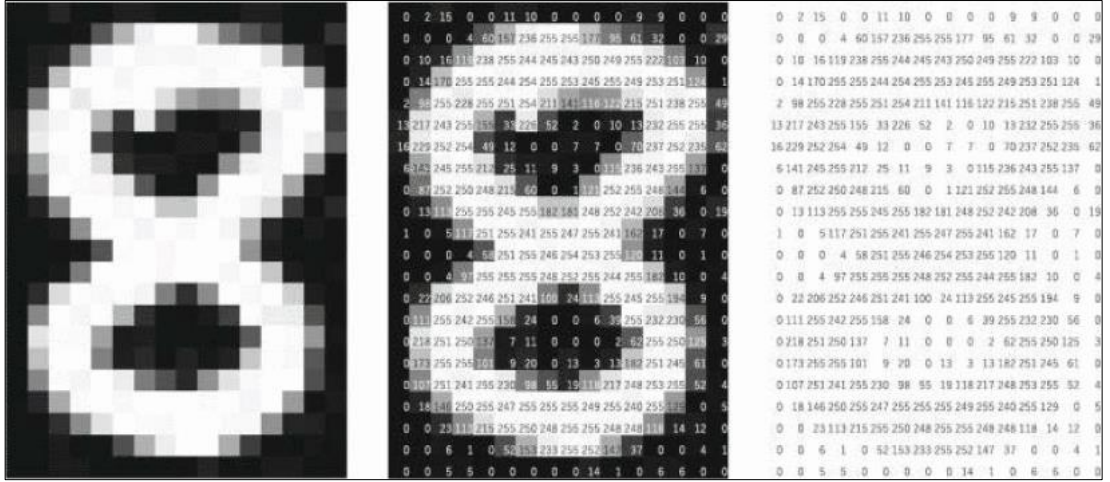
### **2.2.1. Giriş Katmanı**

Evrişimli sinir ağlarının ilk katmanıdır. Veri ham olarak bu katmana verilir. Modelin başarısı ve eğitimin süresi için verilen verinin boyutu önem kazanmaktadır. Giriş katmanından verilen görüntünün boyutu kullanılan bellek miktarını, eğitimin ve test aşamasının süresini uzatabilir. Buna karşılık giriş katmanından verilen görüntünün boyutu düşük olursa kullanılan bellek miktarı, eğitim ve test aşamalarının süreleri kısalsa da modelin performansı düşebilir. Bundan dolayı görüntü boyutu en hızlı eğitim ve en yüksek doğruluğu sağlayacak şekilde, bellek kullanımını da hesaba katılarak çok iyi seçilmelidir [74].

### **2.2.2. Evrişim Katmanı**

Evrişim katmanı, CNN'deki en önemli katmandır. Belirli bir görüntü veya nesne için oluşturulan piksel haritasını, filtreler kullanarak aktivasyon haritası oluşturmak üzere dönüştürür. Şekil 2.7'de el yazısı bir rakam için piksel haritası gösterilmektedir.

Aktivasyon haritasının ana avantajı, işlenecek veri miktarını azaltırken aynı zamanda belirli bir görüntünün tüm ayırt edici özelliklerini saklamasıdır. Verilerin birleştirildiği matris, temel olarak makinenin uyumlu olduğu bir dizi değer olan bir özellik algılayıcıdır. Özellik dedektörünün farklı değerleri kullanılarak görüntünün farklı versiyonları oluşturulur. Kıvrımlı model, her katmanda minimum hata elde etmek için geri yayılımla da eğitilir. En düşük hata setine göre derinlik ve dolgu ayarlanır.



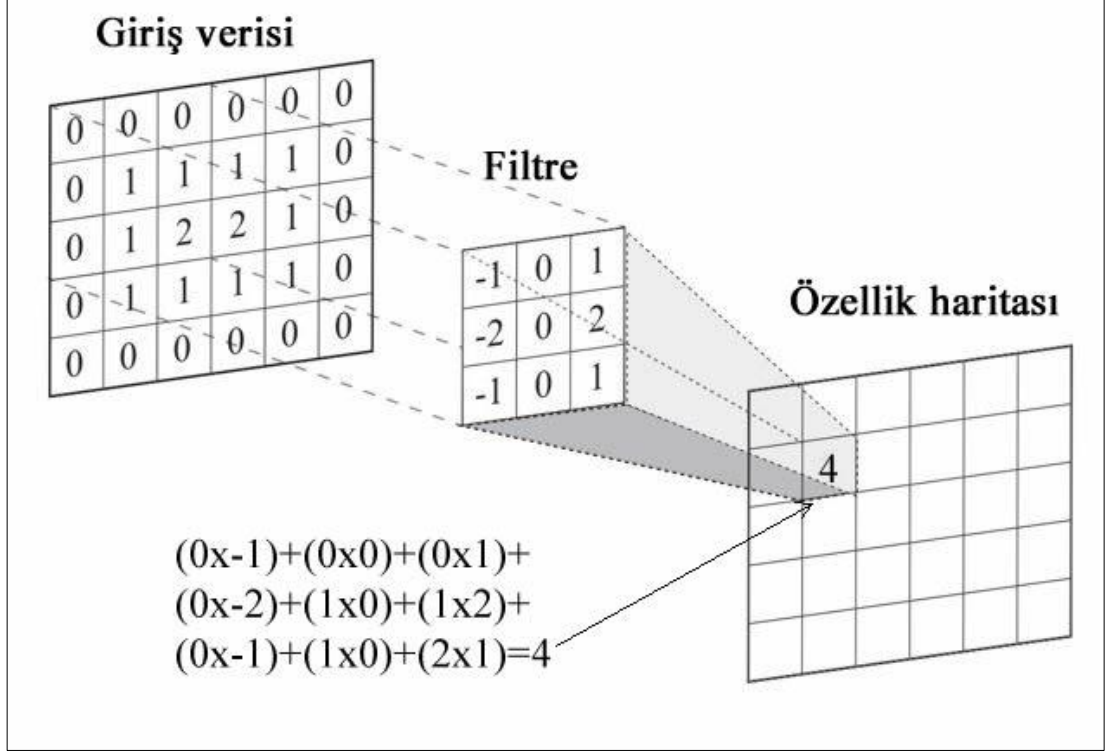
Şekil 2.7. El yazısı rakam için piksel haritası [75].

Şekil 2.8, evrişim işleminde filtrenin nasıl çalıştığını göstermektedir. Bu adım, görüntü verilerini içeren matrisin kıvrılmasını ve ardından bize bir aktivasyon haritası veya bir özellik haritası veren özellik dedektörünü içerir. Evrişimde olan şey, veri ve özellik haritasındaki özdeş konumlardaki değerlerin yani 1 veya 1'den büyük değerlere sahip değerlerin tutulması, geri kalanların çıkarılmasıdır. Görüntü verilerinden elde edilen matris, bir seferde 3x3 olarak karşılaştırılır. Özellik algılayıcının boyutu, kullanılan CNN türüne göre değişir. Örneğin, evrişim için 5x5 ve hatta 7x7 ölçekli filtreler kullanan CNN sürümleri vardır [75].

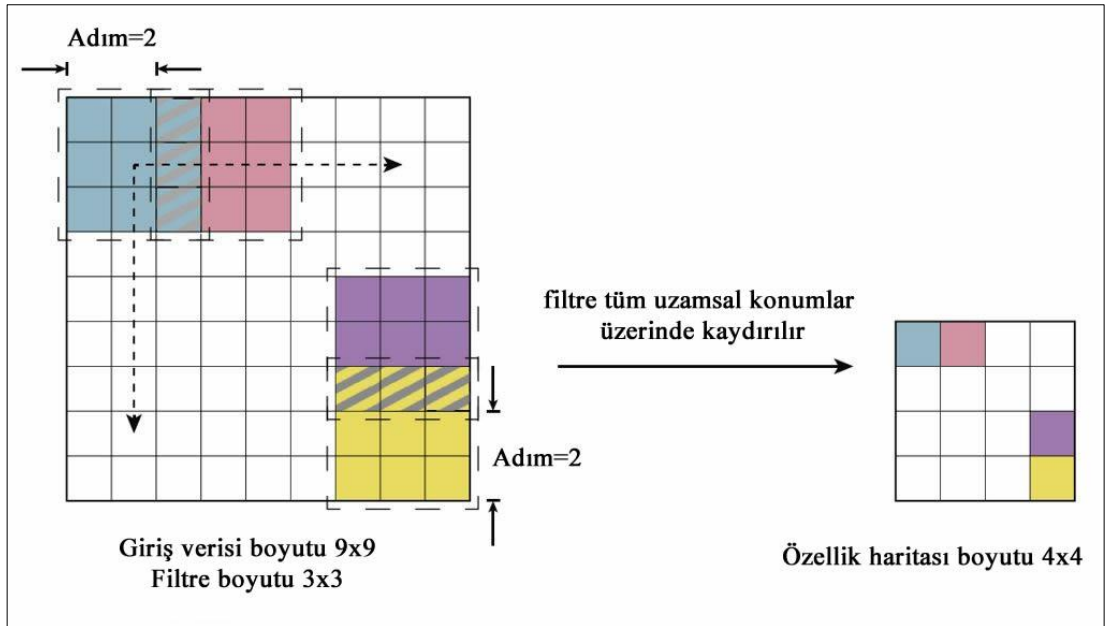
Evrişim işlemi, CNN'lerin uzamsal değişmez olmasına izin veren anahtar adımdır. Evrişim işlemi, filtreyi görüntünün sol üst kısmına yerleştirir. Filtrenin parametreleri ile girişteki eşleşen ızgara arasında eleman bazında bir ürün gerçekleştirecek ve ardından tek bir değer elde etmek için sonucu toplayacaktır. Başka bir deyişle, Şekil 2.8'de gösterildiği gibi bir iç çarpım gerçekleştirecektir. Ortaya çıkan tek değer, görüntünün bu belirli bölümünde filtrenin tek deseninin varlığını veya yokluğunu gösterir. Ardından, evrişim işlemi filtreyi sağa kaydıracak ve iç çarpımı bu yeni konumda hesaplayacaktır.

Filtre kaydırma, giriş boyunca soldan sağa ve yukarıdan aşağıya uygulanır ve görüntünün her konumunda filtrenin uygulanmasına izin verir. Matematiksel olarak,

filtre kaydırma ve nokta çarpımlarının kombinasyonu, bir evrişim işlemi olarak tanımlanabilir. Şekil 2.9'de örnek bir evrişim işlemi gösterilmektedir.



Şekil 2.8. Tek bir nokta çarpımının hesaplanması [76].



Şekil 2.9. Örnek bir evrişim işlemi [76].



Son olarak, özellik haritası evrişim işleminin sonucundaki birçok nokta çarpımının sonuçlarını depolar. Özellik haritasının bu özelliği önemlidir, çünkü sonraki katmanların evrişim işlemleri kritik olarak bu uzamsal ilişkilere bağlıdır [76].


Evrişim katmanının sonucunu doğrusal olmayan hale getirmek için, bir sonraki adımda yetersiz öğrenmenin (underfitting) neden olduğu yok olan gradyan problemini çözecek şekilde ayarlanır. Sigmoid, Tanh, ReLU, Sızdıran Düzeltilmiş Doğrusal Birim (Leaky ReLU), Üstel Doğrusal Birim (ELU) ve Maxout gibi pek çok işlev vardır.

### 2.2.3. ReLU Katmanı

Bu katman, evrişimli katmanlardan sonra gelir ve evrişimli sinir nöronlarının çıktıları için en sık kullanılan yumuşatma birimi olarak bilinir. Denklem 2.1'deki gibi matematiksel olarak tanımlanır ve Şekil 2.10'daki gibi gösterilir.

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (2.1)$$


Bu katman, aktivasyon katmanı olarak da bilinir. Giriş verileri üzerinde, negatif değerleri sıfıra indirerek etki eder. Belirli matematiksel işlemler yapılan bir önceki katmandan olan evrişim katmanında ağ doğrusal bir yapıdadır. Bu katman ile derin ağ, doğrusal olmayan bir yapıya getirmek için kullanılır. Bu katmanı kullanarak ağın daha hızlı öğrenmesi sağlanır [74].



Şekil 2.10. ReLU Fonksiyonu

#### 2.2.4. Havuzlama Katmanı

Bir havuzlama katmanının amacı, girdisinin özet bir istatistiğini üretmek ve özellik haritasının uzamsal boyutlarını azaltmaktır. Bunun için maksimum havuzlama katmanı, her giriş özelliğinin her bir noktasının ( $i, j$  veya 3 boyutlu verileri için  $i, j, k$ ) dikdörtgen komşuluğundaki maksimum değerleri bildirirken, ortalama havuzlama katmanı ortalama değerleri bildirir. Maksimum havuzlamanın en yaygın biçimi, adım boyutu ve çekirdek boyutunu 2 olarak birlikte kullanır. Bu kullanım, özellik haritasını uzamsal olarak, kare veya kübik bloklardan oluşan düzenli bir ızgaraya bölmeye ve her giriş özelliği için bu tür bloklar üzerinden maksimum veya ortalama almaya karşılık gelir. Havuzlama işlemlerinde amaç özellik haritasının uzamsal boyutunu azaltmak olduğunda CNN'lerin ortak yapı taşları olsa da örneğin 2 boyutlu verilerle çalışılıyorsa adım sayısı 2 ile 3x3 evrişim kullanılarak benzer bir hedefe ulaşılabileceği belirtilmelidir. Bu durumda, bilgi kaybını azaltmak ve aynı zamanda daha yüksek seviye özellikleri bir araya getirmek için filtre sayısı aynı anda iki katına çıkarılabilir. Bu alt örnekleme stratejisi, örneğin ResNet [67] mimarisinde kullanılır [77].



Şekil 2.11. Maksimum havuzlama katmanı örneği [76].

Maksimum havuzlama katmanı, önemli bilgileri korurken özellik haritasını altörnekler. Şekil 2.11'de gösterilen her renk farklı bir filtre konumunu belirtir. Maksimum havuzlamanın ardındaki fikir, bir modelin maksimum varlığına bakmanın ortalama varlığından daha bilgilendirici olabilmesidir. Yeni özellik haritası, önce


girdiyi öğrenilmiş bir çekirdekle evriştirerek ve ardından evrilmiş sonuçlara eleman bazında doğrusal olmayan bir aktivasyon fonksiyonu uygulayarak elde edilebilir [72]. Şekil 2.11’de 2x2 penceresi ve 2 adımı olan bir maksimum havuzlama gösterilmektedir.

### 2.2.5. Tam Bağlantılı Katman

Genellikle, bir CNN’nin son katmanları tam bağlantılı katmanlardır. Bu katmanlar, bir DNN ile aynıdır. Ana işlevleri, evrişimli katmanlar ve havuzlama katmanları serisi tarafından algılanan ve çıkarılan özellikler üzerinde sınıflandırma yapmaktır. Tam bağlantılı katmanlara girilmek üzere, özellik haritaları bir boyutlu vektöre düzleştirilir.

### 2.2.6. Seyreltme (DropOut) Katmanı

Evrişimli sinir ağları büyük boyutlu veriler ile işlemlerini gerçekleştirdiğinden, ağın ezberleme yapma ihtimali bulunmaktadır. Ağdaki ezberleme problemini engellemek için bu katman kullanılır [78]. Bu katman ağındaki düğümlerini kaldırarak ezberleme problemini engellemeye çalışır. DropOut katmanının çalışma mantığı Şekil 2.12’de gösterilmiştir.



Şekil 2.12. DropOut işlemi. a) Evrişimli Sinir Ağı. b) DropOut uygulanmış hali.

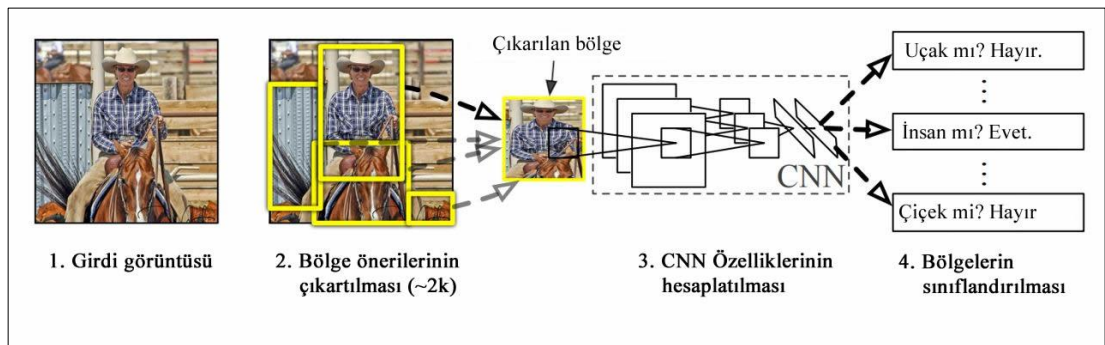
### 2.2.7. Sınıflandırma Katmanı

Tam bağlantılı katmanın hemen ardından gelen bu katman ile sınıflandırma işlemi yapılmaktadır. Katmanın çıkış boyutu sınıf sayısı kadar olmalıdır. Katmanın çıkışında farklı sınıflandırıcılardan en çok softmax sınıflandırıcı kullanılır. 0-1 aralığında üretilen sonuçlardan 1'e en yakın olan sınıf sonuç olarak elde edilir [74].

## 2.3. EVRİŞİMLİ SİNİR AĞLARI

### 2.3.1. R-CNN

R-CNN, nesne algılama için CNN'nin önemli bir kilometre taşıdır. CNN'nin özellik çıkarma ve sınıflandırmasının mükemmel yeteneğine dayalı olarak nesne algılamayı gerçekleştirmek için bölge önerisini öne süren ilk sinir ağıdır. Bölge önerisi, seçici arama gibi farklı genişlik ve yüksekliğe sahip önerileri kaydırarak potansiyel nesnelere alır. CNN'den önce, R-CNN sabit boyutlu aday görüntüleri standarda normalleştirmek için kırpma ve büyütme önerir. CNN'den sonra, kesin nesne algılama sonucunu elde etmek için SVM sınıflandırması ve sınırlayıcı kutu regresyonu ekler. Ancak bölge önerisi, R-CNN'nin devasa veri, zaman, hesaplama ve enerji tüketmesine neden olmakla birlikte; kırpma/çözme işlemi de bilgi kaybına neden olur [79].



Şekil 2.13. R-CNN ile nesne algılama sistemi [4].

Nesne algılama sistemi üç modülden oluşmaktadır. Birincisi, kategoriden bağımsız bölge önerileri üretir. Bu öneriler, dedektör için mevcut olan aday tespit setini tanımlar. İkinci modül, her bölgeden sabit uzunlukta bir özellik vektörü çıkaran büyük

bir CNN'dir. Üçüncü modül, sınıfa özgü doğrusal Destek Vektör Makineleri (SVM) kümesidir. Şekil 2.13'te R-CNN ile nesne tespit sisteminin detaylı şeması gösterilmektedir [4].

### 2.3.2. Fast R-CNN

Fast R-CNN [5], Uzamsal Piramit Havuzu Ağı (SPP-net) [80] modeline dayalı olarak önerilmiştir. SPP-net yöntemi, girdi görüntüsünün tamamı için evrişimli bir özellik haritası hesaplar ve ardından paylaşılan özellik haritasından çıkarılan bir özellik vektörünü kullanarak her nesne önerisini sınıflandırır. Bir teklif için özellikler, teklifin içindeki özellik haritasının bir kısmına sabit boyutlu bir çıktı olacak şekilde maksimum havuzlama yaparak çıkarılır. SPP-net, test zamanında R-CNN'yi 10 ila 100 kat hızlandırır. Tekliflerin özelliklerinin daha hızlı çıkarılması nedeniyle eğitim süresi de 3 kat azalır.

Fast R-CNN, SPP-net'in tüm eğitim sorununu çözen ROI havuzu oluşturma, teklif önerileri ve çoklu görev kayıp katmanını da kullanır. SoftmaxLoss, DVM'nin yerini alır ve SmoothL1Loss, Bouding-box'ın yerini alır. Bu yeni yöntemler, sınıflandırma ve regresyonu birleştirerek algoritmanın kesinliğini artırır. Ek olarak, DVM bağlantılı katmanları hızlandırır. VOC07 veri seti, Fast R-CNN'nin mAP değerinin 70 olduğunu gösterir [79].

### 2.3.3. Faster R-CNN

Fast R-CNN'ye dayalı olarak Faster R-CNN [6], Faster R-CNN'nin ana katkısı olan RPN'yi ekleyerek bölgesel teklif problemini çözmektedir. Bölgesel teklifini orijinal görüntüde değil, ROI havuzuna girilecek olan son özellik görüntüsünden alır. Öznitelik görüntüsünün çözünürlüğü orijinal görüntünün çözünürlüğünden daha düşük olduğu için, Faster R-CNN hesaplaması kesinlikle tüm eski CNN modellerinden çok daha azdır. RPN'nin temel özelliği, teklifi kaydırarak almaktır. Her kayan teklif, farklı ölçek, genişlik ve yüksekliklere sahip 9 aday çapa oluşturacaktır. Faster R-CNN'nin çapaların özelliklerini çıkarma süreci, Fast R-CNN'ninkine benzerken, nesne sınıflandırması yalnızca özelliklerin ön plan veya arka plan olduğunu tanımak

içindir. Öneri regresyonu, yalnızca hedef nesnenin daha kesin bir konumunu bulmak içindir. Teklifin her konumu için RPN, çapaları değerlendirmek ve terk etmek için iki tam bağlantılı katman kullanır. Asla bölgesel öneride bulunmaz.

Çapaları seçmenin ana kuralları şunlardır:

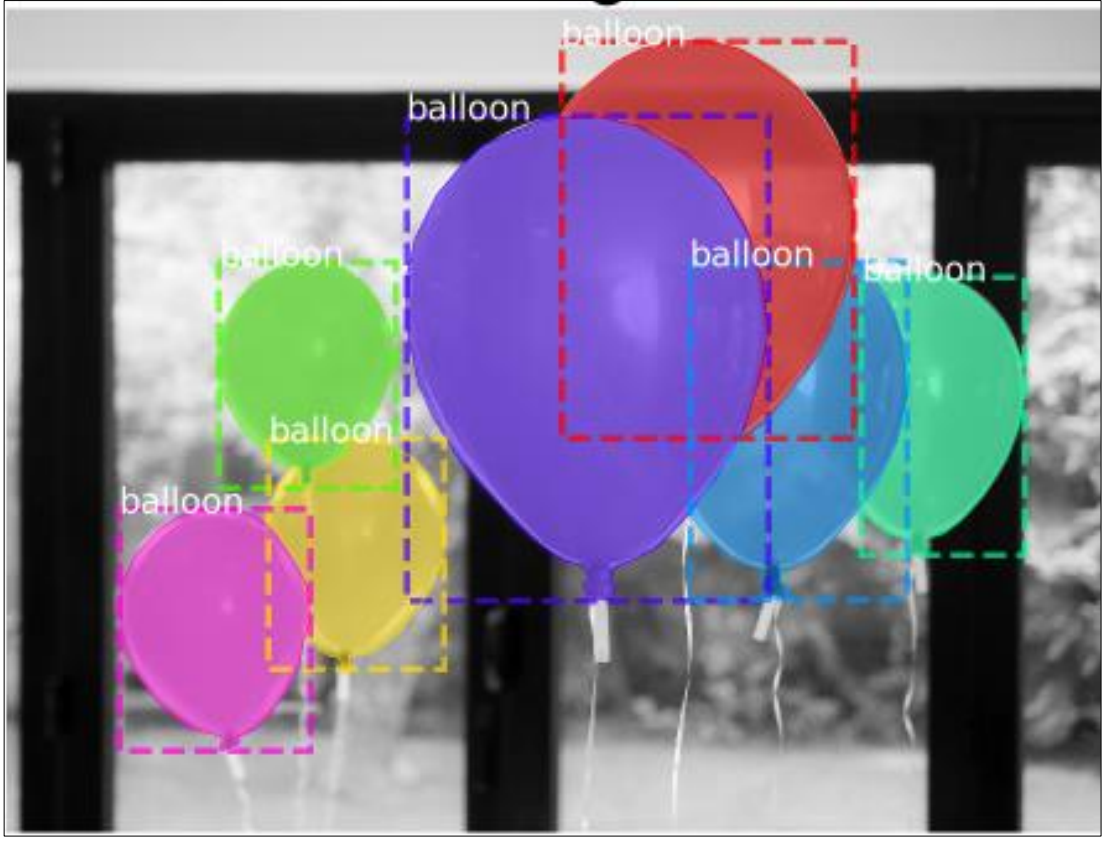
- Sınırdaki çapaları atmalı,
- Örnek ile örtüşen alanları 0,7'den büyük ise ön plan olarak, örtüşen alanları 0,3'ten küçük ise arka plan olarak sınıflandırmalıdır.

Bu şekilde, RPN her kayan teklif için yaklaşık 300 çapa seçer. Faster R-CNN, paylaşılan özellikleri eğitmek için dönüşümlü eğitim modunu kullanır. RPN'nin ağırlığını başlatmak için en son ağı kullanır. Eğitim veri kümesinden doğru önerileri çıkarır ve sonuç iyi bir şekilde yakınsayana kadar Faster R-CNN modelini önerilerle tekrar tekrar eğitir. Faster R-CNN, şimdiden mükemmel tanıma hassasiyetine sahip bir sonuç sunmuştur. Daha fazla iyileştirme için kalan tek alan, daha sonraki algoritmaların çalışmasının ana nedeni olan hızdır [79].

#### **2.3.4. Mask R-CNN**


Bilgisayarla görme görevlerinde kullanılan çeşitli teknikler vardır. Bazıları sınıflandırma, anlamsal bölümlenme, nesne algılama ve örnek segmentasyonunu içerir. Sınıflandırma işlemi görüntünün belirli bir sınıfa ait olduğunu söyler. Bütün bir girdi için bir tahmin yapmaktadır.

Semantik segmentasyon, görüntüdeki her pikselin kendisini çevreleyen nesnenin sınıfıyla etiketlenmesi için her piksel için çıkarım yapan yoğun tahminler yapar. Nesne algılama, yalnızca sınıfları sağlamakla kalmaz, aynı zamanda bu sınıfların mekansal konumunu da gösterir. Nesnelerin üst üste binmesini de hesaba katarak işlemi gerçekleştirir. Örnek segmentasyonu ise ayrıntılı bir şekilde piksel düzeyinde nesnelerin sınırlarının tanımlanmasını içerir. Şekil 2.14'te belirli noktalarda 7 adet balon bulunmaktadır ve örnek segmentasyonu sonucu balonların her birine ait olan piksellerdir [81].



Şekil 2.14. Örnek segmentasyonu.

Örnek segmentasyonu gerçekleştiren Mask R-CNN [82], sınıflandırma ve sınırlayıcı kutu regresyonu için mevcut mimariye paralel olarak her ROI'deki segmentasyon maskelerini tahmin etmek için bir modül ekleyerek Faster R-CNN'yi [6] genişleterek işlem yapar.



Şekil 2.15. Örnek segmentasyonu için Mask R-CNN çerçevesi [82].

Şekil 2.15'te gösterildiği gibi maske modülü, her ROI'ye uygulanan küçük bir FCN'dir ve pikselden piksele bir segmentasyon maskesini tahmin eder. Çok çeşitli esnek mimari tasarımlarını kolaylaştıran Faster R-CNN çerçevesi göz önüne alındığında Mask R-CNN'nin uygulanması ve eğitilmesi kolaydır. Ek olarak, maske modülü yalnızca küçük bir hesaplama yükü ekleyerek hızlı bir sistem ve hızlı deneyler sağlar [82].

Mask R-CNN kavramsal olarak basittir. Faster R-CNN'nin her aday nesnesi için bir sınıf etiketi ve bir sınırlayıcı kutu ofseti olarak iki çıkışı vardır. Bu çıkışlara Mask R-CNN ile nesne maskesini veren üçüncü modül eklenmiştir. Mask R-CNN bu nedenle doğal ve sezgisel bir fikir sunar. Ancak ek maske çıktısı, sınıf ve kutu çıktılarından farklıdır ve bir nesnenin çok daha ince uzamsal düzeninin çıkarılması işlemlerini gerektirir [7].

Mask R-CNN, ilk aşaması RPN'nin aynısı olan iki aşamalı işlemi uygular. İkinci aşamada, sınıfı ve kutu ofsetini tahmin etmeye paralel olarak Mask R-CNN ayrıca her bir ROI için bir ikili maske çıkarır. Bu, sınıflandırmanın maske tahminlerine bağlı olduğu en yeni sistemlerin tersidir. Bu yaklaşım, sınırlayıcı kutu sınıflandırması ve regresyonunu paralel olarak uygulayan Fast R-CNN mantığını takip eder. Bu, orijinal R-CNN'nin çok aşamalı ardışık düzenini büyük ölçüde basitleştirmiştir.

Eğitim sırasında, örneklenen her bir ROI'de çoklu görev kaybı Eşitlik 2.2'de verildiği şekli ile hesaplanır. Burada sınıflandırma kaybı  $\mathcal{L}_{cls}$  ve sınırlayıcı kutu kaybı  $\mathcal{L}_{box}$  olarak ifade edilmiştir.

$$\mathcal{L} = \mathcal{L}_{cls} + \mathcal{L}_{box} + \mathcal{L}_{mask} \quad (2.2)$$

Maske modülünün, her  $K$  sınıfı için bir tane olmak üzere, çözünürlüğü  $m \times m$  olan  $K$  ikili maskesini kodlayan her bir ROI için bir  $Km^2$  boyutlu çıktısı vardır. Buna piksel başına bir sigmoid uygulanır ve  $\mathcal{L}_{mask}$  ortalama ikili çapraz entropi kaybı olarak ifade edilir. Temel gerçeklik sınıfı  $k$  ile ilişkili bir ROI için,  $\mathcal{L}_{mask}$  yalnızca  $k$ 'inci maske üzerinde tanımlanır. Diğer maske çıktıları kayba katkıda bulunmaz [83].



$\mathcal{L}_{mask}$  tanımı, ağın sınıflar arasında rekabet olmaksızın her sınıf için maskeler üretmesine izin verir. Çıktı maskesini seçmek için kullanılan sınıf etiketini tahmin etmek için özel sınıflandırma kullanılır. Bu, maske ve sınıf tahminini birbirinden ayırır [7].

Maske, bir girdi nesnesinin uzamsal düzenini kodlar. Bu nedenle, tamamen bağlı katmanlar tarafından kısa çıktı vektörlerine daraltılan sınıf etiketlerinden veya kutu ofsetlerinden farklı olarak, maskelerin uzamsal yapısının çıkarılması, evrişimler tarafından sağlanan pikselden piksele karşılık gelme yoluyla doğal olarak ele alınır. Aslında yapılan her ROI'den bir  $m \times m$  maske tahmin etmektir. Bu, maske modülündeki her katmanın, uzamsal boyutları olmayan bir vektör temsiline daraltmadan, açık  $m \times m$  nesne uzamsal düzenini korumasına izin verir. Maske tahmini için tamamen bağlı katmanlarına başvuran önceki yöntemlerden farklı olarak, tamamen evrişimli yöntem daha az parametre gerektiren işlem yapar ve daha doğru sonuçlar üretir.

Bu pikselden piksele davranış, kendileri de küçük özellik haritaları olan ROI özelliklerinin, piksel başına belirgin uzamsal boyutlarını aslına sadık bir şekilde korumak için iyi hizalanmasını gerektirir. Bu, maske tahmininde önemli bir rol oynayan ROI hizalama katmanı ile gerçekleştirilir [82].

#### **2.4. SEZGİSEL ALGORİTMALAR ve YAKLAŞIMLAR**

Modern problemler çok karmaşık olma eğilimindedir ve büyük veri setlerinin analizi ile ilgilidir. Sezgisel algoritmalar, problem çözme, öğrenme ve keşif için deneyime dayalı teknikleri ifade eder. Tam olarak bir çözüme ulaşamadığında veya algoritmik yaklaşım kullanılarak çözüm bulunamadığı zaman çözüm için tasarım yapan kişinin tecrübesi ile problemin çözülmesine dayanan bir yöntemdir. Ayrıca, kapsamlı bir işlemin pratik olmadığı durumlarda, tatmin edici bir çözüm bulma sürecini hızlandırmak veya bulunan çözümü iyileştirmek için de sezgisel yaklaşımlar kullanılır [84,85].

## 2.5. SINIFLANDIRMA MODELLERİNDE BAŞARI KRİTERLERİ

Çizelge 2.1’de gösterildiği gibi karmaşıklık matrisi, tahmin edilen ve gerçek değerleri gösteren kullanışlı bir tablo olarak modelin performansını değerlendirmek için kullanılır. Derin öğrenme modelinin başarısı, doğru pozitif, yanlış pozitif ve yanlış negatif tahmin sayıları kullanılarak hesaplanır.

Çizelge 2.1. Karmaşıklık matrisi.

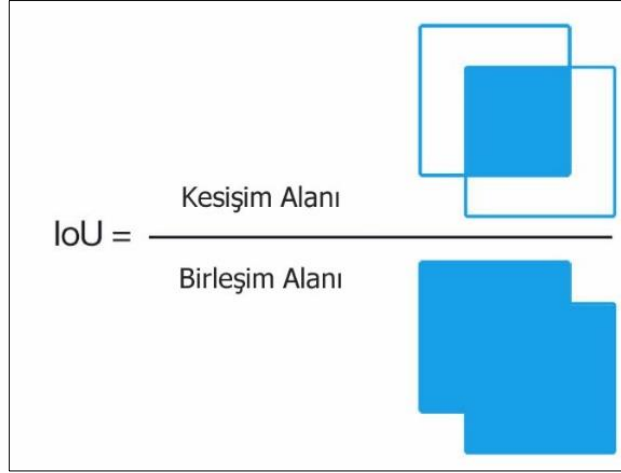
	<b>Gerçek Pozitif</b>	<b>Gerçek Negatif</b>
<b>Tahmin Edilen Pozitif</b>	Doğru Pozitif	Yanlış Pozitif
<b>Tahmin Edilen Negatif</b>	Yanlış Negatif	Doğru Negatif

Doğru pozitif değeri, temel gerçekteki dış sınıfının, ya da restorasyon sınıflarının model tahminlerinde de aynı şekilde görüntülenmesidir. Yanlış negatif değeri, temel gerçekteki dış sınıfının, ya da restorasyon sınıflarının model tahminlerinde yanlış olduğunu gösterir. Yanlış pozitif değeri, temel gerçekteki etiketlenmemiş bölgenin model tahmininde bir nesne olarak tahmin edildiği durumdur. Doğru negatif değeri, temel gerçekteki etiketlenen bir nesnenin dışındaki bölgenin modeldeki doğru tahminidir.

IOU, Şekil 2.16’da gösterildiği gibi temel gerçek verisinin sınırlayıcı kutusu ile tahmin edilen sınırlayıcı kutuyu karşılaştırarak nesne algılama performansını değerlendirmek için kullanılır.

Pay tahmin edilen sınırlayıcı kutu ile temel gerçeklik sınırlayıcı kutu arasındaki kesişim alanıdır. Payda tahmin edilen sınırlayıcı kutu ile temel gerçeklik sınırlayıcı kutusunun kapladığı alan yani birleşim alanıdır. Kesişim alanını birleşim alanına bölmek bize IOU puanını vermektedir. İkili maske  $I$ , Mask R-CNN çıktısı  $F$  arasındaki IOU puanın matematiksel olarak hesaplanması Eşitlik 2.3’te gösterilmiştir.

$$IoU_{I,J} = \frac{I \cap B(F)}{I \cup B(F)} \quad (2.3)$$



Şekil 2.16. Birleşim üzerinden kesişim.

Kesinlik (Precision), doğru tahmin edilen sınıfların gerçekte hangi oranda doğru tahmin edildiğinin bir göstergesidir. Matematiksel olarak Eşitlik 2.4'te gösterilmiştir.

$$Kesinlik = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} \quad (2.4)$$

Duyarlılık (Recall) metriği olarak da bilinen geri çağırmanın, modelin, temel gerçeğin tüm pozitiflerini bulmada ne kadar iyi olduğunu ölçmek için kullanılır. Doğru tahmin edilen dış sayısının tüm tahminlere oranı, bu hesaplamada gerçekte dış olan nesnelere için elde edilir. Matematiksel olarak Eşitlik 2.5'te gösterilmiştir.

$$Duyarlılık = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (2.5)$$

F1-puanı metriği, kesinlik ve duyarlılığın ne kadar iyi dengelendiğini belirler. Daha yüksek bir F1-puanı hem kesinliğin hem de duyarlılığın yüksek olduğunu gösterir. Daha düşük bir F1-puanı, daha yüksek kesinlik ve dengesiz duyarlılığı gösterir. F1-puanı bize kesinlik ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir. Matematiksel olarak Eşitlik 2.6'da gösterilmiştir.

$$F1 - puanı = 2 \times \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (2.6)$$

mAP, öncelikle nesne algılama modellerini değerlendirmek için kullanılan bir ölçümdür. mAP hesaplanırken hatırlama ve kesinlik kullanılır. Bir sınıftaki tüm kesinlik ve duyarlılık değerlerinden geçen bir döngü kullanılarak, mevcut ve sonraki duyarlılık arasındaki fark hesaplanır ve ardından mevcut kesinlik ile çarpılır. Başka bir deyişle AP, hatırlamadaki artış olduğundan her bir eşikteki hassasiyetlerin ağırlıklı toplamıdır. Her sınıfın ortalama kesinlik (AP) değeri Eşitlik 2.7'deki gibi hesaplanır.

$$AP = \sum_{k=0}^{k=n-1} [Duyarluluk(k) - Duyarluluk(k + 1)] \times Kesinlik(k) \quad (2.7)$$

Bu formülde  $n$ , eşik sayısı anlamına gelir.  $k = n-1$ 'e kadar eklemenin nedeni,  $k, n$  olduğunda kesinliğin 1 ve geri çağırmanın 0 olmasıdır. mAP, tüm sınıfların ortalamasını elde etmek için AP değerlerinin toplamının sınıf sayısı olan  $N$  değerine bölünmesiyle elde edilir. Tüm sınıflar için AP'lerin ortalaması olan mAP matematiksel olarak Eşitlik 2.8'de gösterilmiştir.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (2.8)$$

## BÖLÜM 3

### DENTAL RADYOGRAFİ TÜRLERİ ve PANORAMİK RADYOGRAFİLERİN ETİKETLENMESİ


Diş hekimliğinde kullanılan radyografi türleri, ağız içi (intraoral) ve ağız dışı (extraoral) olmak üzere iki başlık altında incelenir. Ağız içi radyografiler temel diş hekimliği radyolojisini oluşturmaktadır. Bu radyografiler ile dişler ve diş çevresinde bulunan dokular incelenir. Çenelerde bulunan daha büyük lezyonların bu radyografiler ile görüntülenmesi mümkün olmamaktadır. Kafatası ve fasiyal yapıların, maksilla ve mandibuladaki patolojileri görüntülemek için ağız dışı radyografi türleri kullanılır. Ağız dışı radyografi tekniklerinde ışın kaynağı ve film ağız dışında bulunmaktadır [86].

Diş hekimliğinde günlük muayene işlemlerinde çeşitli türlerde görüntüleme teknikleri kullanılmaktadır. Bu tekniklerden biri olan panoramik radyografiler, hastanın maksillofasiyal bölgesindeki bilgileri tek bir röntgen ile sunduğu ve görüntüyü elde etme işlemi hasta açısından diğer ağız içi radyoloji tekniklerine göre daha kolay ve konforlu olduğundan uzmanlar tarafından sıklıkla tercih edilmektedir. Ancak, uzmanların bir panoramik diş röntgenini yorumlamak için harcadıkları inceleme süresi genellikle uzun ve zahmetli bir süreçtir. Bu durumlar dikkate alındığında diş hekimliği uygulamalarında dişlerin numaralandırılması ile dolgu, implant, kanal tedavisi, protez gibi restorasyonların tespit edilmesinde panoramik radyografi görüntülerinin analizinin yapılmasına karar verilmiştir.

#### 3.1. DENTAL RADYOGRAFİLER

Dental görüntülemelerde kullanılan radyografik teknikler ağız içi ve ağız dışı olmak üzere iki grupta ele alınmaktadır. Ağız içi radyografi teknikleri periapikal, bitewing, okluzal radyografiler olarak, ağız dışı radyografi tekniklerinin başlıcaları ise

panoramik, sefalometrik ve bilgisayarlı tomografi (CT) olarak adlandırılırlar. Diş hekimleri hangi yöntemi kullanacağına görüntülemenin amacına ve hastanın işlemi tolere etme kabiliyetine bağlı olarak karar vermektedir [87].



Şekil 3.1. Dental radyografi tipleri. a) Periapikal b) Bitewing c) Panoramik.

Ağız içi radyografi, dental görüntülemelerde halen en yaygın kullanılan radyografik tekniktir. Bir X-ışını üretici ve ağız içi algılayıcı aracılığıyla, ağız içindeki küçük bir bölgenin radyografisi elde edilir. Ağız dışı radyografi ise, dişleri, çeneyi ve kafatasını kapsayan daha büyük bir bölgenin tanısal görüntülerini oluşturur ve ağız dışı görüntüleme radyografisi ve tomografik görüntüleme olarak alt bölümlere ayrılabilir.

Geleneksel görüntülemeler özellikle yüz iskeletini veya büyümesini değerlendirmek için yararlı olsa da diş hekimliğinde 3 boyutlu bilgiye duyulan ihtiyaç tomografik ve panoramik görüntülemelerde birçok gelişmeye yol açmıştır [88]. Şekil 3.1'de sırasıyla

periapikal, bitewing ve panoramik yöntemleri kullanılarak çekilmiş röntgen örnekleri gösterilmektedir.

### 3.1.1. Panoramik Dental Radyografi

Panoramik radyografiler, maksillofasiyal bölgenin kapsamlı bir incelemesini elde etmek için yaygın olarak kullanılmaktadır. En büyük avantajlarından biri, ağız içi radyografi yöntemlerine kıyasla hastanın daha az radyasyona maruz kalmasıdır [89,90]. Panoramik görüntüleme, görüntü dedektörü ve X-ışını kaynağı eş zamanlı bir şekilde zıt yönlerde hareket eder. Görüntü dedektörü hastanın yüzüne mümkün olduğunca yakın geçer. Bu hareketle at nalı şeklinde bir odak oluğu veya belirli kalınlıkta bir dilim oluşturulur [87].



Şekil 3.2. Örnek bir panoramik röntgen görüntüsü.

Panoramik görüntüleme cihazlarında, standart görüntülerle birlikte çocuklar ve erişkinler gibi farklı büyüklükte çene yapısına sahip hastaların görüntülenebilmesi için çeşitli ayarlamaların yapılabildiği özellikler bulunmaktadır. Şekil 3.2’de görüldüğü gibi panoramik cihazlar çene, temporomandibular eklem ve maksiller sinüs görüntülerini detaylı bir şekilde alabilir. Yeni geliştirilen cihazlar üç boyutlu dijital volumetrik tomografi ve çok katmanlı panoramik görüntü elde edilmesine imkân tanır [86].

### 3.1.2. Sefalometrik Dental Radyografi

Ortognatik cerrahi ve ortodontik tedavi planlaması genellikle sefalometrik radyografiler gerektirir. Sefalometrik radyografilerin en önemli avantajı, yeniden üretilebilir olmasıdır. Çünkü kafatasındaki (sella turcica) belirli yapılar, büyümenin, hastalık veya cerrahinin etkisinin doğrulanması için referans olarak kullanılmaktadır.

Sefalometrik görüntüleme için uygun hasta konumlandırması için sefalostatlı özel bir X-ışını cihazı kullanılır. Tekrarlanabilir yanal kafatası görünümü görüntülerinin üretilmesine izin verir. Sefalostat, kafatasının midsagittal düzlemini zemine dik olarak hizalamak için harici akustik kanallara sokulan iki kulak çubuğu ve hastanın kafasının doğal pozisyonunu korumak için burun köprüsü üzerinde bir destek içerir. Görüntüleme sırasında hastanın dişleri ise kapalı bir konumdadır.



Şekil 3.3. Örnek bir sefalometrik röntgen görüntüsü.



Hareket artefaktlarını önlemek için tek atış yöntemi, ön-arka veya kafatasının tersi taraması gibi farklı teknikler kullanan farklı üreticilerden çeşitli sefalometrik X-ışını cihazları mevcuttur. Radyasyon maruziyetini azaltmak için oluşturulmuş X-ışını alanları da mevcuttur. Sefalostat döndürülebilir ve birkaç kafatası radyografik görüntüsüne izin verir. Şekil 3.3'te görüldüğü gibi sefalometrik görüntüler her zaman hasta sağ tarafa bakacak şekilde izlenmelidir. Ortognatik ve ortodontik analizlerde tedavi planlaması için yüz ve boyunu örten yumuşak dokuların sefalometrik görüntülerde de görülmesi gerekir [87].

### **3.1.3. Konik Işınlı Bilgisayarlı Tomografi**

Konik Işınlı Bilgisayarlı Tomografi (CBCT), tek bir dişi veya dişi çevreleyen iskelet dokularıyla ilişkili olarak görselleştirilecek ve incelenecek alanın üç boyutlu görüntülerini oluşturmak için nispeten yeni bir yöntemdir. CBCT'nin endodontide kullanımını dünya çapında hızla artmaktadır [91]. CBCT, geleneksel CT'ye kıyasla önemli ölçüde daha düşük etkili radyasyon dozu ile dişler ve onları çevreleyen dokular dahil olmak üzere maksillofasiyal iskeletin bozulmamış üç boyutlu bilgilerini üretmek için özel olarak tasarlanmıştır. Periapikal görüntülere kıyasla CBCT kullanılarak periapikal hastalık daha erken saptanabilir ve periapikal lezyonların gerçek boyutu, kapsamı, doğası ve konumu değerlendirilebilir. Kök kırıkları, kök kanal anatomisi ve diş çevresindeki alveoler kemik yapısı değerlendirilebilir.

CBCT ile, hastanın başının etrafında 180°–360° arasında senkronize olarak dönen sensör ve kaynak arasında basit, tarayıcının tek bir taraması sırasında üç boyutlu bir veri hacmi elde edilir. X-ışını koni şeklindedir ve tekniğin adı da buradan gelir. Görüş alanı olarak tanımlanan silindirik veya küresel bir veri hacmini yakalar [92].

## **3.2. PANORAMİK DENTAL VERİ KÜMESİ VE VERİ ETİKETLEME**

Diş hekimliğindeki en büyük zorluklardan biri, radyoloğun birçok görüntüyü sınırlı sürede yorumlaması ve hızlı bir tedavi planının sunulmasının zorunlu olmasıdır. Yeterli zamanın olmaması, tecrübe eksikliği ve konsantrasyon kaybı gibi insani koşullar, yapay zekâ destekli otomatik analiz sisteminin gerekliliğini tartışmasız bir

şekilde ortaya koymaktadır. Derin öğrenme modelleri özellikle dental görüntülerin analizinde, anormalliklerin tespitinde, görüntü segmentasyonunda ve sınıflandırılmasında kullanılmaktadır. Dijital teknolojilerin klinik sorunların tanı, görüntüleme, tedavi planlaması ve tedavi sürecinde kullanılması, harcanan süreyi kısaltmakta ve tedavide oluşabilecek olumsuz durumların ortaya çıkmadan önce tahmin edilmesine yardımcı olmaktadır [93]. Klinik uygulamaların yanı sıra hızla gelişen teknolojisi sayesinde üç boyutlu grafik modeller, çevrimiçi videolar ve mobil cihazlar (akıllı telefonlar, tablet bilgisayarlar) da diş hekimliği eğitimlerine her geçen gün dahil olmaktadır. Son zamanlarda gelişen teknoloji cihazlarının eğitim faaliyetlerinde ve hemen hemen her alanda kullanılmasının öğrenme performansını etkilediği araştırmacılar tarafından ortaya konmuştur [94]. Dişlerin yapı ve özelliklerinin belirlenmesi adli radyolojide de önemli bir yere sahiptir. Adli tıpta radyografiler zor vakaların çözülmesine yardımcı olmuştur [95].

Dental radyolojide tanı süreci insan hatası göz önünde bulundurularak gerçekleşir. Bu durum, tanı süreçlerinde zamanla bilgisayar destekli uygulamaların yer almasına neden olmuştur. CAD, tıbbi görüntüleme ve tanı radyolojisinde önemli araştırma konularından biri haline gelmiştir [96]. CAD, doktorların ve radyologların bilgisayar çıkışını göz önünde bulundurarak karar vermelerine yardımcı olur. Diş hekimliğinde görüntü yorumlama, tanı, diş sağlığının izlenmesi ve tedavi planlamasında önemli bir rol haline gelen radyografik görüntülerin işlenmesiyle birlikte gelen otomatik çözümler, diş hekimlerine yardımcı olduğu gibi günlük pratikte zaman kaybı, stres ve yorgunluğun olumsuz etkilerini de azaltır.

Çeşitli alanlarda kullanılan dental radyoloji yöntemleri, uzmanlar tarafından uzun süreler içerisinde değerlendirildiğinden insan hatasını en aza indirmek, uzmanların iş yükünü hafifletmek, otomatik raporlama yapabilmek için yapay zekâ yöntemleri içeren sistemler geliştirilmektedir. Yapay zekâ tabanlı sistemlerin, dişleri ve özelliklerini öğrenebilmesi için büyük miktarlarda radyografik görüntüye ihtiyaç duymaktadır. Bu radyografi türlerinden biri olan panoramik radyografiler, çene ve dişlerde kist, çürük ve tümör gibi görünmez oluşumların tespiti için gerekli olan, ağız ve dişlerin tamamının bir arada görüldüğü, daha hızlı ve eksiksiz tedavi planlaması sağlayan bir diş röntgenidir. Periapikal görüntüler sadece birkaç diş içerir. Kısıtlı bir

alanın görüntülenmesini sağlarlar. Bu sebeplerden dolayı daha detaylı bir analiz yapabilmek için bu tez çalışmasında panoramik radyografiler kullanılmıştır.


### 3.2.1. Panoramik Dental Veri Seti

Bu çalışma, Karabük Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu tarafından 2021/451 referans numarası ile onaylanmıştır. Kullanılan radyografiler Karabük Eğitim ve Araştırma Hastanesi Ağız ve Diş Sağlığı Merkezi arşivinden kişisel bilgiler olmadan anonimleştirilmiş şekilde alınmıştır.

	Sağ Üst							Sol Üst									
Sağ	18	17	16	15	14	13	12	11	21	22	23	24	25	26	27	28	Sol
	48	47	46	45	44	43	42	41	31	32	33	34	35	36	37	38	
	Sağ Alt							Sol Alt									

Şekil 3.4. FDI diş numaralandırma sistemi.

Bu görüntüler, iki dental radyolog tarafından dişlerin sınırlarını belirlemek için yazarı tarafından hazırlanan web tabanlı etiketleme yazılımı DentiAssist ile etiketlenmiş ve FDI numaralandırma sistemine göre toplamda 32 sınıf olarak numaralandırılmıştır. FDI numaralandırma sistemi Şekil 3.4'te gösterilmiştir.



Şekil 3.5. Radyologlar tarafından yapılan diş etiketleme ve numaralandırma örneği.

Modelin doğruluğunu test etmek için modelin eğitim sürecinde kullandığı görüntülerin kullanılması yararlı değildir. Modelin güvenilirliğini artırmak için modelin daha önce hiç görmediği tamamen yeni bir veri kümesi kullanmak gereklidir [97]. Bu nedenle modelin test veri seti eğitim veri setinden bağımsız olarak oluşturulmuştur. Şekil 3.5, iki dental radyolog tarafından etiketlenmiş veri kümesinden bir panoramik radyografi örneğini göstermektedir.

### 3.2.2. Panoramik Radyograflerin Etiketlenmesi

Tıbbi görüntü sınıflandırma görevleri için mevcut yapay zekâ algoritmaları genellikle denetimli bir öğrenme yaklaşımına dayalıdır. Bu, bir yapay zekâ algoritmasının eğitilmesi ve test edilmesinden önce temel gerçeğin tanımlanması ve görüntüye bağlanması gerektiği anlamına gelir. Temel gerçek terimi tipik olarak doğrudan gözlemden elde edilen bilgileri ifade eder. Görüntü etiketleri, radyologlar gibi tıp uzmanları tarafından gerçekleştirilen ek açıklamalardır [98].

DENTIASIST

Zekice!

Lütfen Giriş Yapın.

E Posta Adresi

Şifre

9HES Güvenlik Kodu

Giriş Yap

**i** Bilgi ×

Oturum Sonlandırıldı.

DENTIASIST - 2021

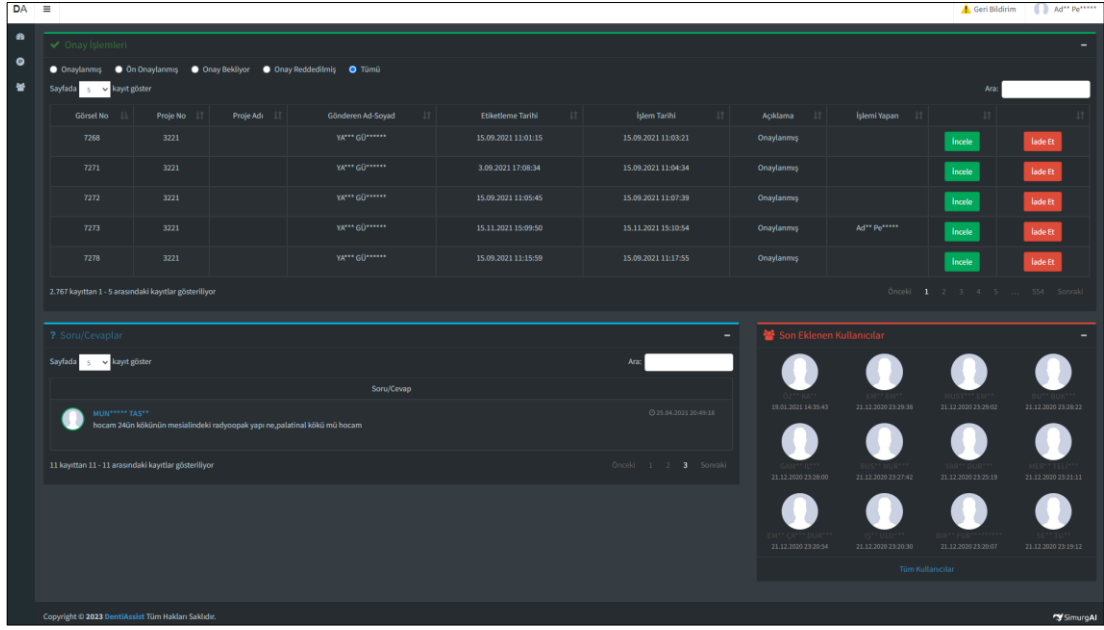
Şekil 3.6. Kullanıcı giriş ekranı.

Bu tez çalışmasında, web tabanlı DentiAssist veri etiketleme yazılımı kullanılmıştır. Uygulama arayüzü açıldığında kullanıcının sisteme giriş yapması için gerekli bilgilerin girildiği “Kullanıcı Giriş Ekranı” açılmaktadır. Bu ekrandan kullanıcılar bilgilerini girerek sisteme giriş yapabilmektedirler. Kullanıcı giriş ekranı Şekil 3.6’da gösterilmiştir.

Üç kullanıcı rolü vardır. Bunlardan birincisi “yönetici” rolüdür. Yönetici rolü sistem üzerindeki tüm işlemleri yapabilme yetkisine sahiptir. Sistemi kullanıma açma/kapatma, veritabanı yedekleme, işlem kayıtlarını görüntüleme gibi sistemsel işlemleri yapabilir. Kullanıcı rollerinin ikincisi “eğitici” rolüdür. Eğitici rolündeki bir kullanıcı yönetici rolündeki sistemsel işlemler haricindeki diğer tüm işlemleri yapabilir. Bu işlemlerden bazıları yeni proje oluşturma, oluşturulan projeye görüntü ekleme, sisteme yeni öğrenci ekleme, öğrenci bilgilerini değiştirme, oluşturulan projeyi bir öğrenciye atama olarak söylenebilir. Kullanıcı rollerinin sonuncusu “öğrenci” rolüdür. Bu rol yetkileri daha kısıtlı bir roldür. Öğrenci kullanıcısının yapabileceği işlemler kendine atanmış projedeki görseller üzerinde etiketleme işlemlerini yapma, görüntü ile ilgili soru ekleme olarak sıralanabilir.

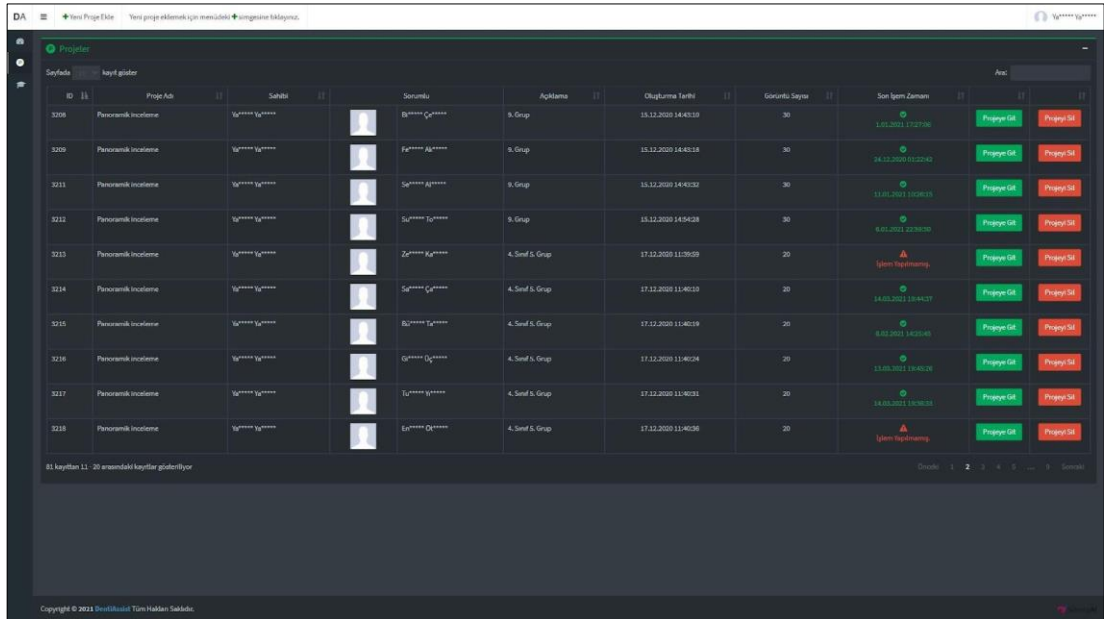
Sistem arayüzü dört temel bölümden oluşmaktadır. Birinci bölüm üst kenarda yatay olarak konumlandırılmış “üst menü”, ikinci bölüm sol kenarda dikey olarak konumlandırılmış “sol menü”, üçüncü bölüm alt kenarda yatay konumlandırılmış “alt bilgi”, dördüncü bölüm ise ilk üç bölümden kalan alan içerisinde konumlandırılmış “içerik” alanıdır. Üst menünün sağ köşesinde giriş yapan kullanıcının resmi, adı ve soyadı yer alır. Sol menü içerisinde kullanıcıların sistem içerisindeki ilgili ekranlara gidebilecekleri yönlendirme linkleri bulunmaktadır. Bu bölüm ekranda en az alan kaplayacak şekilde tasarlanmıştır. Kullanıcı isterse üst menüdeki kısımdan bu yönlendirme linklerinin olduğu alanı genişletebilir. Alt bilgide sistem hakkında genel bilgiler ve yazılım sürüm bilgisi gösterilir. İçerik alanında sol menüden gidilen ekranların içerikleri görüntülenir.

Kullanıcı sisteme giriş yaptıktan sonra “karşılama ekranı” görüntülenir. Bu ekranda kullanıcılara, sorulan yeni sorular, etiketleme işlemi onay bekleyen, onyalanmış ya da onayı reddedilmiş görseller gösterilir. Karşılama ekranı Şekil 3.7’de gösterilmiştir.



Şekil 3.7. Karşılama ekranı.

Eğitmen kullanıcı, kendisine sorulmuş bir soru ya da öğrenci kullanıcı, sorusuna verilmiş bir cevap var ise sorunun ya da cevabın üzerine tıklayarak sorunun ait olduğu görsele ve soruya cevap verebileceği ilgili görselin soru/cevap bölümüne girmek üzere yönlendirilir. Ayrıca her bölmede bulunan arama bölümü ile kriter girerek arama gerçekleştirebilir.



Şekil 3.8. Proje ekranı.

Kullanıcılar sol menüden “Projeler” sayfasına geçiş yapabilir. Projeler çalışma yapılacak görsellerin farklı kullanım amaçlarına yönelik gruplar halinde oluşturulabilmesine ve oluşturulan projelerin öğrencilere sorumlu olarak atanabilmesine imkân verir. Proje ekranı Şekil 3.8’de gösterilmiştir.

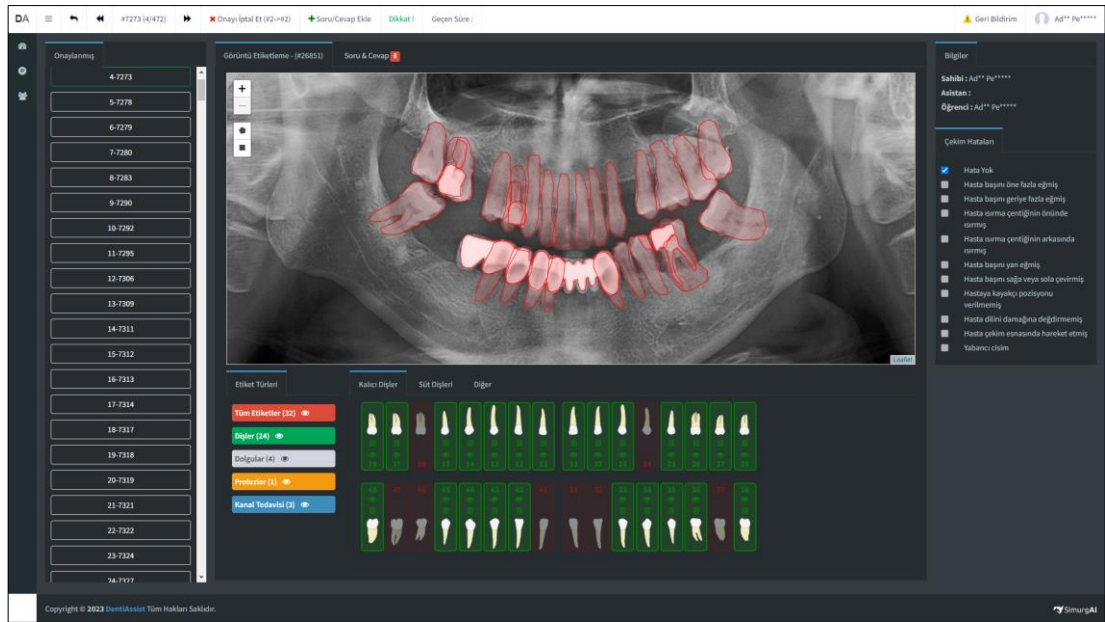
Projeler sayfasında kullanıcının oluşturduğu ya da kendisine atanmış projeleri görür. Projelerin adı, kim tarafından oluşturulduğu, kimin sorumluluğunda olduğu, proje açıklaması, oluşturulma tarihi, sorumluluğunda olan kişinin proje üzerinde herhangi bir işlem yapıp yapmadığı, eğer işlem yaptı ise en son yapılan işlemin tarih ve saat bilgileri detaylı olarak gösterilir. Kullanıcılar bu alanlarda sıralama yapabilecekleri gibi arama çubuğu üzerinden belirli kriterlere göre aramalarını gerçekleştirebilirler. Üst menüde bulunan “Yeni Proje Ekle” linki ile yeni proje eklenebilir. Here bir projenin detay bilgilerinin en sonunda proje üzerinde yapılabilecek işlemler listelenir. Projeyi oluşturan yani sahibi projeyi kalıcı olarak silebilir.

Kullanıcılar “Projeye Git” linki ile projenin içerisindeki görüntülerin ve detayların gösterildiği ve görsellere etiketleme yapılabilen ekrana yönlendirme linkinin olduğu ekrana geçiş yapılabilir. Proje detay ekranı Şekil 3.9’da de gösterilmiştir.

ID	Sahibi	Görsel Adı	Açıklama/Kolordör	Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6150	Y*****Y*****	3208_Q1q2d3u4v5C.bmp	etiketli, profiz	Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6141	Y*****Y*****	3208_J1D078R9U.bmp		Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6142	Y*****Y*****	3208_q3n7C3abk.bmp		Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6143	Y*****Y*****	3208_QyWU4nyj.bmp		Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6144	Y*****Y*****	3208_p4kZ0S4qj.bmp		Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6145	Y*****Y*****	3208_BH4W03nyj.bmp		Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6146	Y*****Y*****	3208_B45W4L4d4j.bmp		Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6147	Y*****Y*****	3208_d4dGca4U.bmp		Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6148	Y*****Y*****	3208_h0w9jnyj4.bmp		Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil
6149	Y*****Y*****	3208_P544F24j.bmp		Görüntü	Etiketlemeye Git	Kalıcı Olarak Sil

Şekil 3.9. Proje detay ekranı.

Proje detay ekranında projenin içerisindeki görseller listelenir. Üst menüde bulunan “Görsel Ekle” linki ile yeni görsel eklenebilir. Bu ekleme işlemi toplu görsel yükleme işlemi destekler. Yüklemenin durumu görsel olarak kullanıcıya gösterilir. Yükleme tamamlandığında görseller listede görüntülenir. Görsellerin adı, kim tarafından eklendiği, görsel anahtar kelimeleri detaylı olarak gösterilir. Kullanıcılar bu alanlarda sıralama yapabilecekleri gibi arama çubuğu üzerinden belirli kriterlere göre aramalarını gerçekleştirebilirler. Her bir görselin detay bilgilerinin en sonunda görsel üzerinde yapılabilecek işlemler listelenir. Kullanıcılar herhangi bir görseli kalıcı olarak silebilir. Özellikler linkinden görsel ile ilgili anahtar kelimeler girilebilir. Bu özellik sayesinde belirli bir ortak özelliğe sahip görüntüler filtrelenip listelenebilir. Kullanıcılar “Etiketlemeye Git” linki ile projenin içerisindeki görüntülerin etiketleme işlemlerinin yapıldığı ekrana geçiş yapılabilir. Etiketleme ekranı Şekil 3.10’da gösterilmiştir.



Şekil 3.10. Veri etiketleme ekranı.

Üst menüde bulunan gezinti düğmeleri ile kullanıcılar projedeki görseller arasında kolayca geçiş yapabilirler. Ayrıca bu bölüme proje ekranına geri dönebilmek için de bir düğme konumlandırılmıştır. Gezinti düğmelerinin içerisinde projede kaç görüntü olduğu ve geçerli görüntünün numarası ile proje içindeki sırası görüntülenir. Bu menüde kullanıcıların ilgili görsel ile ilgili soru ekleyebilecekleri bir link

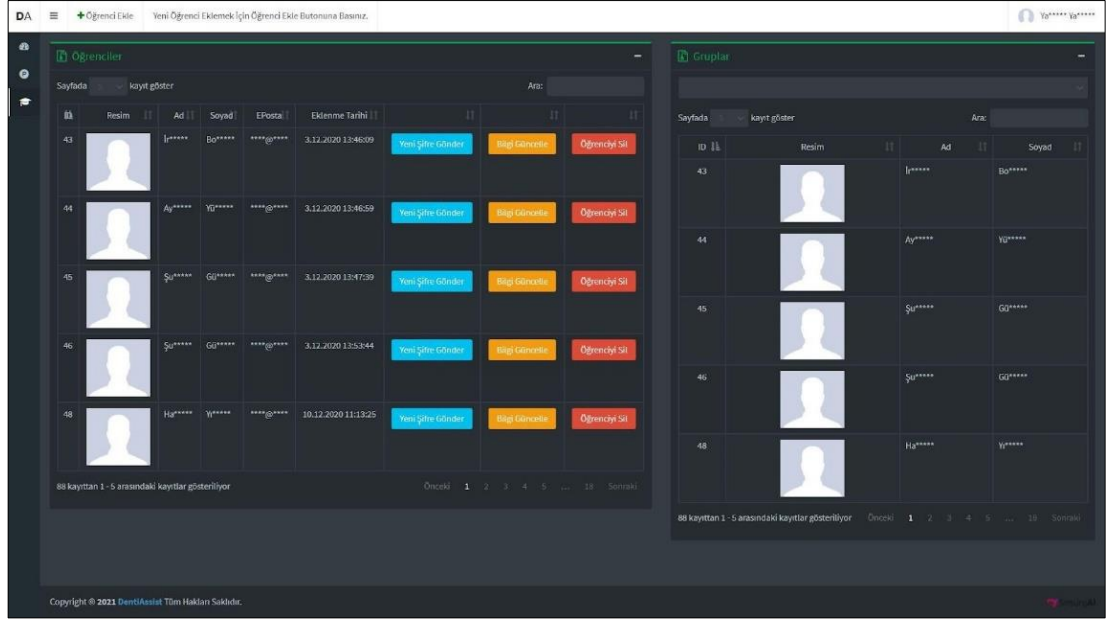


bulunmaktadır. Bu link ile özellikle öğrenciler görüntü üzerinde çalışırken başka bir ekrana geçiş yapmadan kolaylıkla öğretmenlerine soru sorabilirler. Burada sorulan sorular ilgili öğretmenin sisteme kullanıcı girişi yaptığında açılan karşılama ekranında listelenir. Kullanıcı bu listeden herhangi bir soruya tıkladığında sorunun ait olduğu görsele yönlendirilir ve soru/cevap etkinliğinin yapıldığı bölüme odaklanır. Buraya soruya cevabını girerek işlemi gerçekleştirir.

Ekranda içerik kısmında ilgili görüntünün görüntülediği, etiketleme işlemlerinin yapıldığı ve görsel ile ilgili bilgilerin gösterildiği iki kısım bulunur. Kullanıcı görsel üzerinde herhangi bir çekim hatası tespit ederse bilgiler kısmındaki listeden uygun hatayı seçer ve üst menüde bulunan kaydet simgesine tıklayarak kaydedilmesini sağlar. Kullanıcı etiketleme işlemlerini gerçekleştirirken görüntü içerisinde sol kısımda bulunan işaretleme araçlarından birini seçer. Bu araçlar dörtgen ve çoklu seçim olacak şekilde seçimlere izin verir.

Kullanıcı etiketlemeyi bitirdiği anda ekrana dış şablonu ve dış üzerindeki yapılabilecek işlemlerin listesi gösterilir ve kullanıcı bu listeden etiketlediği bölgeye uygun olan etiketi seçer. Etiket seçildiği anda görüntünün alt kısmındaki etiketler listesine etiketin özellikleri ile eklenir. Bu listede görüntü üzerindeki etiketler tamamen gösterime kapatılabileceği gibi etiket bazlı da görüntülemeyi açma ve kapatma işlemi yapılabilir. Gerekliğinde etiket listesinden seçilen etiket silinebilir. Görüntü üzerindeki etikete tıkladığında etiket yeniden düzenleme görünümünde açılır ve etikette gerekli düzeltmeler yapılabilir. Düzenleme sonunda tekrar etikete tıkladığında düzenleme görünümü kapanır. Görüntü üzerinde yakınlaştırma ve uzaklaştırma işlemi görüntü üzerindeki sol kısımdaki menüden yararlanacağı gibi fare üzerindeki kaydırma çubuğunu da kullanabilir. Klavyeden Ctrl tuşu ile aynı anda farenin sol düğmesine basarak görüntüyü kaydırabilir. Dış olarak etiketleme için harcanan süre saniye cinsinden tutulur. Tüm bu işlemler üst menüdeki kaydetme simgesine basılarak veritabanına json formatında kaydedilir.

Kullanıcılar sol menüden “Kullanıcılar” sayfasına geçiş yapabilir. Yatkili kullanıcılar bu ekrandan sisteme öğrenci ekleyebilirler. Kullanıcılar ekranı Şekil 3.11’de gösterilmiştir.



Şekil 3.11. Kullanıcı ekranı.

Bu ekranda kullanıcı kendi eklemiş olduğu öğrencileri listeleyebilir. Üst menüde bulunan “Öğrenci Ekle” linki ile yeni öğrenci eklenebilir. Ayrıca belirli öğrencileri gruplandırılabilir. Her bir öğrencinin sistemde kayıtlı elektronik posta adresine yeni şifre gönderebilir, öğrenci bilgilerini düzenleyebilir ve öğrencileri silebilir.

## BÖLÜM 4

### DERİN ÖĞRENME VE SEZGİSEL YAKLAŞIM İLE DENTAL RADYOGRAFİ ANALİZİ

Bu bölümde iki çalışmanın detayları verilmiştir. Birinci çalışmada dental panoramik radyografilerdeki dişlerin numaralandırılması, ikinci çalışmada ise implant, kanal tedavisi, dolgu ve protez restorasyonlarının segmentasyonu gerçekleştirilmiştir.

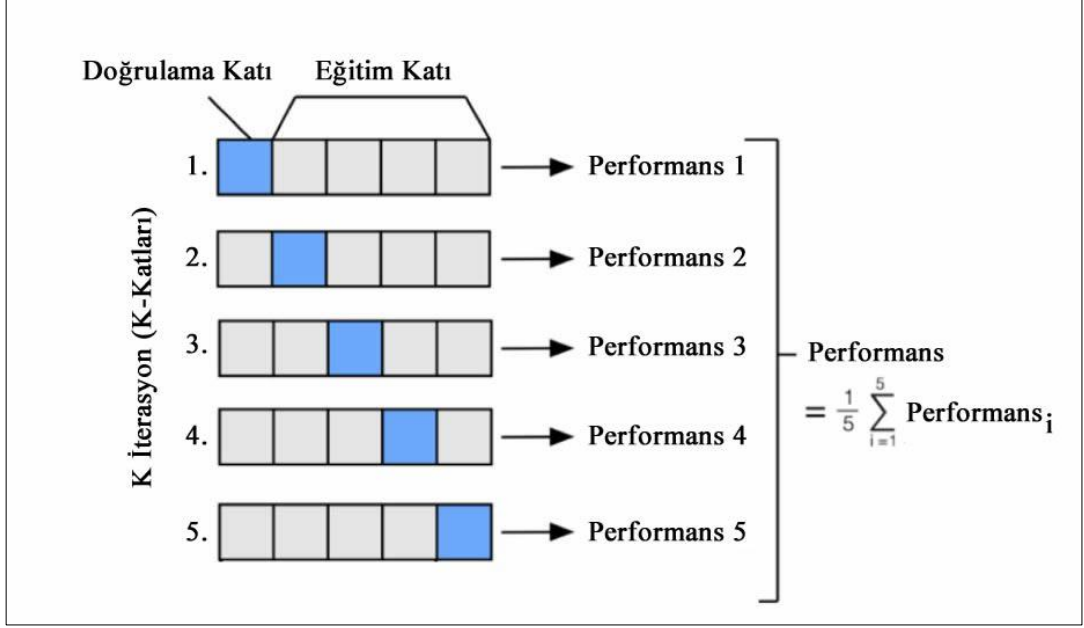
#### 4.1. DIŞLERİN ÖRNEK SEGMENTASYONU VE NUMARALANDIRILMASI

Bu çalışmada panoramik radyografilerdeki dişlerin örnek segmentasyonu ve numaralandırılması için derin öğrenme algoritması ve temel modelin sonuçlarını iyileştirmek için geliştirilmiş olan sezgisel algoritma sunulmaktadır. Önerilen yöntem, geleneksel derin öğrenme algoritmasının çıktılarını alarak sezgisel bir yaklaşım ile sonuçları iyileştirmeyi ve yüksek doğruluk elde etmeyi amaçlamaktadır. Ayrıca bu çalışma diş hekimlerinin iş yükünü azaltacak ve teşhise yardımcı olacak yeni bir yöntem önermektedir. Birinci adım panoramik görüntülerdeki dişlerin FDI numaralandırma sistemine göre derin öğrenme algoritması ile otomatik olarak algılanması, bölütlenmesi ve numaralandırılmasıdır. İkinci adım, temel model sonuçlarındaki çift numaralı olan dişlerin tahmin hatalarını geliştirilen sezgisel yöntem ile düzelterek tek ve doğru numaralandırma yapmaktır. Üçüncü adım ise hatalı numaralandırılmış dişleri tespit ederek doğru numaralandırma yapacak şekilde düzeltilmesidir.

##### 4.1.1. Veri Setinin Hazırlanması


K-Katlı Çapraz Doğrulama (KÇD) tekniği, sınıflandırıcıların model seçimi ve hata tahmini için uygulayıcılar tarafından en çok kullanılan yaklaşımlardan biridir. KÇD,

bir veri setinin Şekil 4.1’de gösterildiği gibi k adet alt sete bölünmesinden oluşur. Daha sonra yinelemeli olarak, bazı alt veri setler modeli öğrenmek için kullanılırken diğerleri performansını değerlendirmek için kullanılır [99]. Bu çalışmada da veri setini değerlendirmek için KÇD kullanılmıştır.



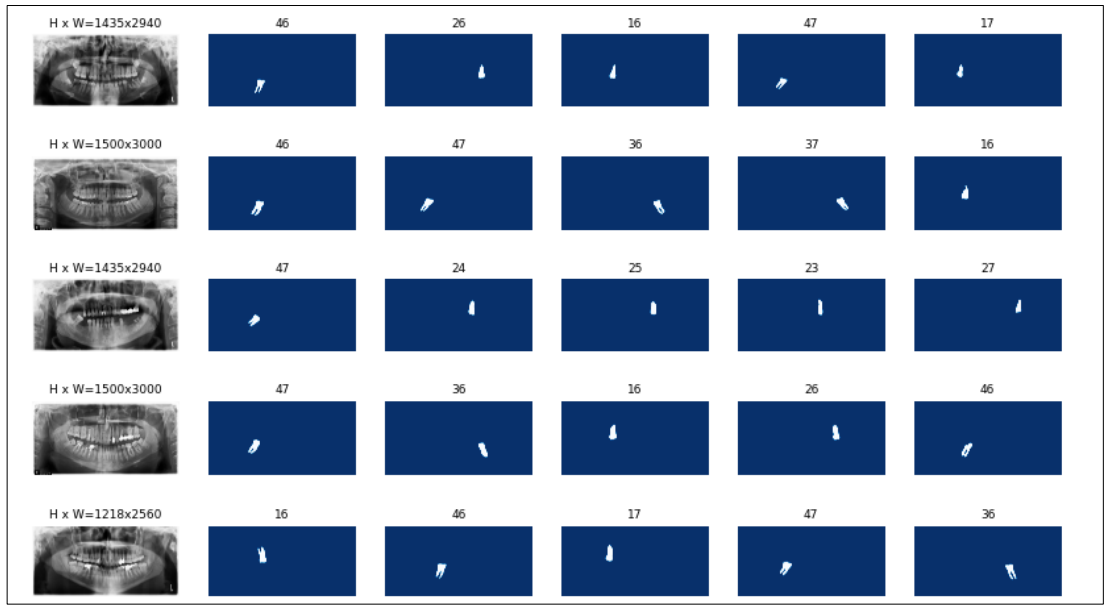
Şekil 4.1. K-Katlı çapraz doğrulama.

Veri setinde bulunan toplam 2702 adet görüntünün 2231 görüntüsü, modelin eğitimi için bir eğitim veri seti olarak, kalan 471 adet görüntü ise test veri seti olarak rastgele seçilmiştir. Eğitim veri seti, KÇD (k=5) olarak, her katta 1747 eğitim görüntüsü ve 484 doğrulama görüntüsü kullanılarak doğrulanmıştır. Eğitim setindeki dış sınıfı etiketlerinin dağılımı Şekil 4.2’te gösterilmiştir.



Şekil 4.2. Eğitim setindeki dış etiketlerinin dağılımı.

Veri seti içerisinde, eksik dişler, dolgu, implant, kanal tedavisi ve protez restorasyonlarının olduğu görüntüler bulunmaktadır. Veri seti içerisindeki bu çeşitlilik modelin test edilirken farklı özellikteki görüntüler ile karşılaşmasını ve doğruluk ölçümlerinin daha güvenilir gerçekleştirilmesini sağlamaktır. Ayrıca model eğitiminde farklı özelliklerde görüntülerin kullanılması ile modelin her durumda yüksek doğrulukta tahminler üretmesi amaçlanmıştır. Model eğitiminde kullanılan panoramik radyografilerden bazılarının model eğitim sürecindeki maske olarak görünüşleri Şekil 4.3'te gösterilmektedir.

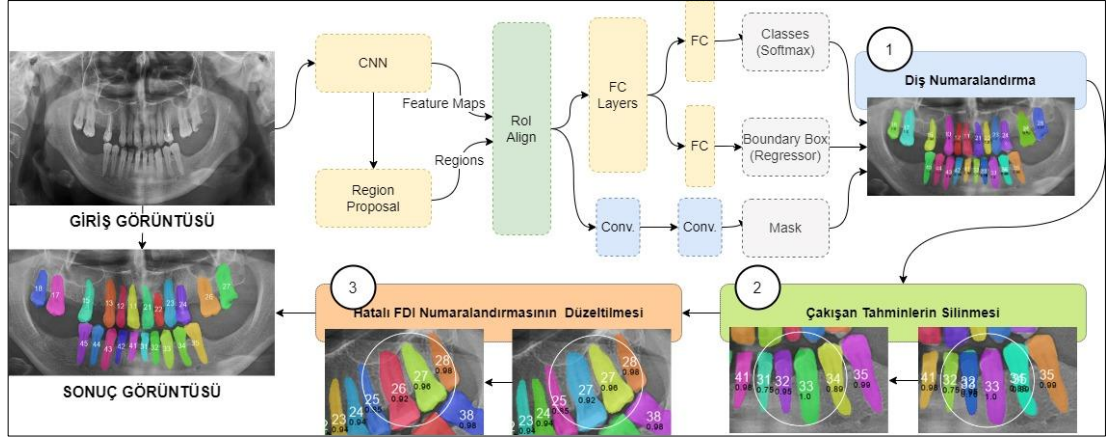


Şekil 4.3. Model eğitiminde kullanılan görüntülerden bazı diş örneklerinin maske görünüşleri.

#### 4.1.2. Model

Mask R-CNN modeli, bir görüntüdeki nesneleri algılama, sınıflandırma ve maskeleme yeteneğine sahip bir Faster R-CNN'nin geliştirilmesiyle oluşturulmuş CNN'ye dayalı bir algoritmadır. Mask R-CNN modelinin temel özelliği, bir görüntüdeki her bir ilgi nesnesini tespit etmeye ve tanımlamaya yönelik yaklaşım olan örnek segmentasyonu gerçekleştirmesidir [82].

Dişlerin segmentasyonu ve numaralandırılması için Mask R-CNN ve sezgisel algoritmanın iş hattı Şekil 4.4'te gösterilmiştir.



Şekil 4.4 Sistem mimarisi ve iş hattı.

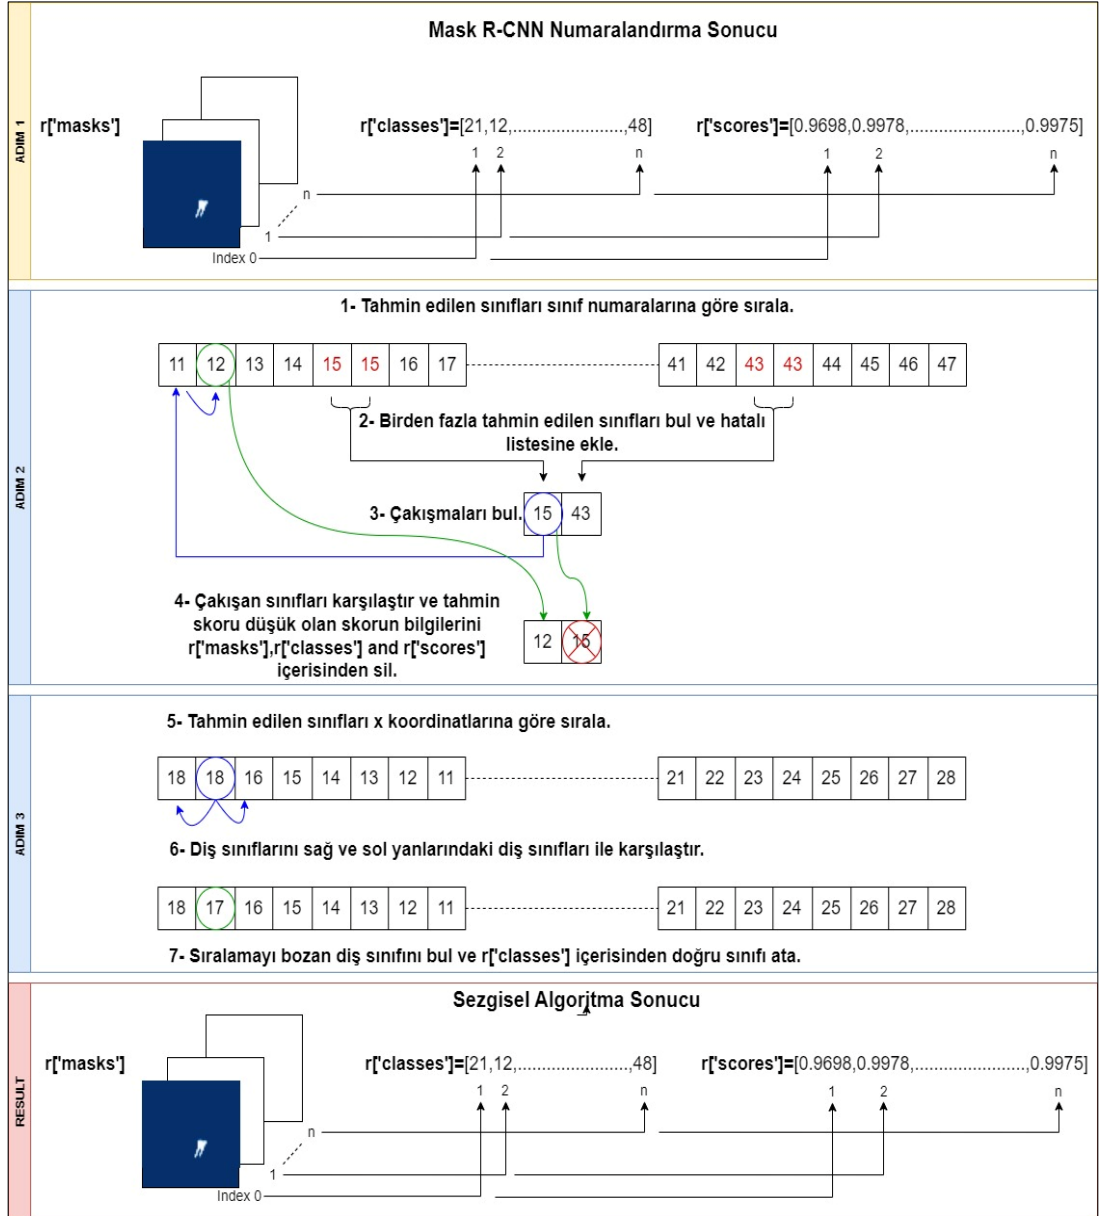
Mask R-CNN, örnek segmentasyon görevini gerçekleştirmek için bir özellik çıkarıcı görevi gören evrimsel sinir ağlarının bir dalını içerir. Omurga ağı olarak görüntü özelliklerini ayıklayan ResNet-101 [67] ağı tercih edilmiştir. Bir Mask R-CNN, ilk aşamasında RPN olarak adlandırılan görüntüdeki nesne olmaya aday ROI'ler önerdiği, ardından sınıflandırma ve sınırlayıcı kutu tahminlerine paralel olarak her ROI için bir ikili maske üreten iki kısımdan oluşur [82].

Şekil 4.4'te gösterildiği gibi, panoramik diş radyografisinde bulunan diş nesneleri iki adımlı RPN ağından geçirilmiştir. Artık omurga ağından diş görüntülerinin özellikleri haritalanarak havuzlama katmanına gönderilmiştir. Çakışma kutuları Maksimum Olmayan Bastırma (NMS) yöntemine göre taranmıştır. Nesneleri içeren bölgeler, modelde bulunan bağlantı tabanlı yaklaşımla belirli bir eşik değerine sahip bölümlere ayrılmıştır. Havuzlama katmanındaki maksimum değerler CNN'ye seçilmiştir.

Ağın bir sonucu olarak, görüntülerde ilgili bölgenin alanı başına sınırlayıcı kutu ve maske oluşturulmuştur. Bu nedenle, tanımlanacak belirli nesnelere, Şekil 4.4'te gösterildiği gibi kendi sınıflarının segmentasyon maskeleri ile sınırlayıcı kutulardadır.  $\mathcal{L}_{mask}$ , segmentasyon maskelerini ifade eder.  $\mathcal{L}_{mask}$ , matematiksel olarak Eşitlik 4.1'de gösterilmiştir.

$$\mathcal{L}_{mask} = -\frac{1}{m^2} \sum_{1 \leq i, j \leq m} [y_{ij} \log \hat{y}_{ij}^k + (1 - y_{ij}) \log (1 - \hat{y}_{ij}^k)] \quad (4.1)$$

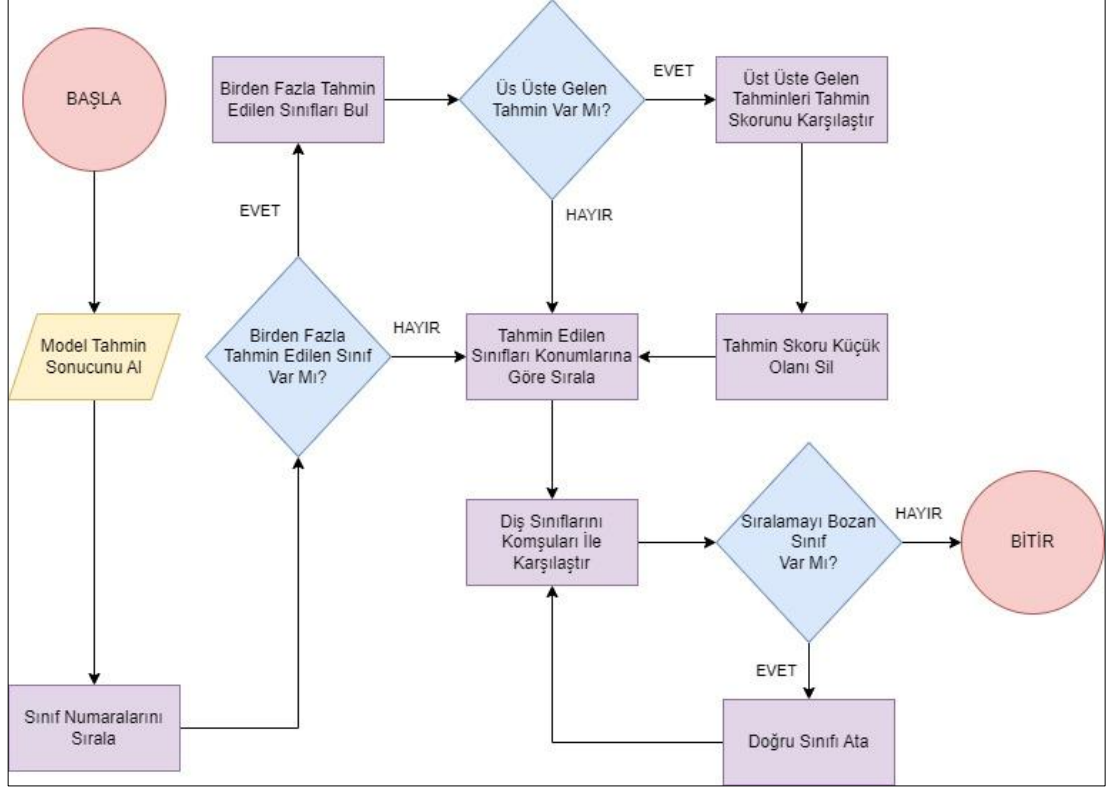
$k$ , toplam sınıf sayısını temsil eder. Her sınıf ve ROI için,  $m \times m$  boyutunda bir maske oluşturulmuştur. Çıktı boyutu  $k \times m^2$  olarak ayarlanmıştır.  $\hat{y}_{ij}^k$  Eşitlik 4.1'deki  $k$  sınıfı için tahmin edilen değerdir. Denklemdaki  $y_{ij}$ , oluşturulan maskedeki bir noktanın  $(i,j)$  etiketidir.



Şekil 4.5. Geliştirilen sezgisel yaklaşım.

Mask R-CNN çıkışı, panoramik radyografilerdeki dişlerin maskeleri şeklindedir. Bu sonuç maskeleri, aynı diş için çoklu numara atamalarını ve numaralandırma hatalarını kaldırarak modelin doğruluğunu iyileştirmek için geliştirilen sezgisel bir algoritmaya

iletilir. Modelin tahmin sonuçlarını iyileştirmek için kullanılan bu üç adımlı sezgisel yaklaşımın yapısı Şekil 4.5'te, akış diyagramı Şekil 4.6'da gösterilmiştir.



Şekil 4.6. Sezgisel yaklaşımın genel akış diyagramı.

Temel model, bazı dişler birbirine çok benzer olduğunda aynı diş için birden fazla diş sınıfını tahmin edebilir. Sezgisel yaklaşımın ilk adımı bu soruna odaklanmıştır. Sezgisel yaklaşım ile birden fazla numaralı dişi tespit etmek için, tahmin edilen dişler önce tahmin edilen sınıflara göre sıralanmıştır. Sıralama sonucunda birden fazla numaraya sahip dişler numaralar kontrol edilerek belirlenmiştir. Daha sonra birden fazla numaralandırmaya sahip tahminlerin diğer tahminlerle çakışıp çakışmadığına bakılmıştır. Bu kontrol, tahmin edilen sayıların maskelerinin örtüşmelerine karşı kontrol edilmesiyle gerçekleştirilmiştir. Sonuç olarak çakışan sınıflar tespit edilmiş ve tahmin puanı en düşük olan sınıfın maskesi, tahmin puanı ve sınıf bilgisi silinmiştir.

Daha sonra numaralandırma hatalarına çözüm geliştirilmiştir. FDI diş numaralandırma sistemine göre ağızdaki dişlerin belirli bir sıralaması vardır. Tahmin edilen dişlerin sırasının bu sisteme göre uygun olup olmadığını kontrol etmek için tahmin edilen diş



maskelerinin koordinatları x eksenine göre artan şekilde sıralanmıştır. Daha sonra ilk dişten başlanarak dişlerin FDI numaraları komşu dişlerin numaraları ile karşılaştırılmıştır. Bu karşılaştırma sonucunda sıralamayı bozan diş belirlenmiş ve bu dişe doğru FDI numarası atanmıştır.

#### **4.1.3. Modelin Eğitimi**

Model, deneysel çalışmalarda i9 10980XE işlemci ve NVIDIA Quadro RTX 5000 ekran kartına sahip bir bilgisayar üzerinde eğitilmiştir. Mask R-CNN modelinin farklı boyutlardaki verilerle uyumlu olması için kullanılan veri seti görüntüleri 1024x1024 olarak ayarlanmıştır. Sinir ağına ağırlık atamak için önceden eğitilmiş bir veri seti olan MS COCO ağırlıkları kullanılmıştır. MS COCO veriseti, 4 yaşındaki bir çocuk tarafından kolayca tanınabilecek 91 nesne türünün fotoğraflarını içermektedir. Veri setinin oluşturulmasında kategori tespiti, örnek tespiti ve örnek segmentasyonu için yeni kullanıcı arayüzleri aracılığıyla kapsamlı katılım ile 328 bin görüntüde toplam 2,5 milyon etiket verisi elde etmişlerdir [100].

Model, parti boyutu 1, öğrenme oranı 0,001 ve epok başına adım sayısı 100 olacak şekilde 400 epok eğitilmiştir. Derin öğrenme modelini ve geliştirilen sezgisel yöntemi oluşturmak için Python programlama dili, Keras kütüphanesi ve Tensorflow kullanılmıştır.

#### **4.2. DİŞ RESTORASYONLARININ TESPİTİ VE SEGMENTASYONU**

Bu çalışmada uzman dental radyologlar tarafından oluşturulan etiketler ile kanal tedavisi, implant, dolgu ve protez dental restorasyon nesnelere arka plandan ayırma görevi gerçekleştirilmiştir.

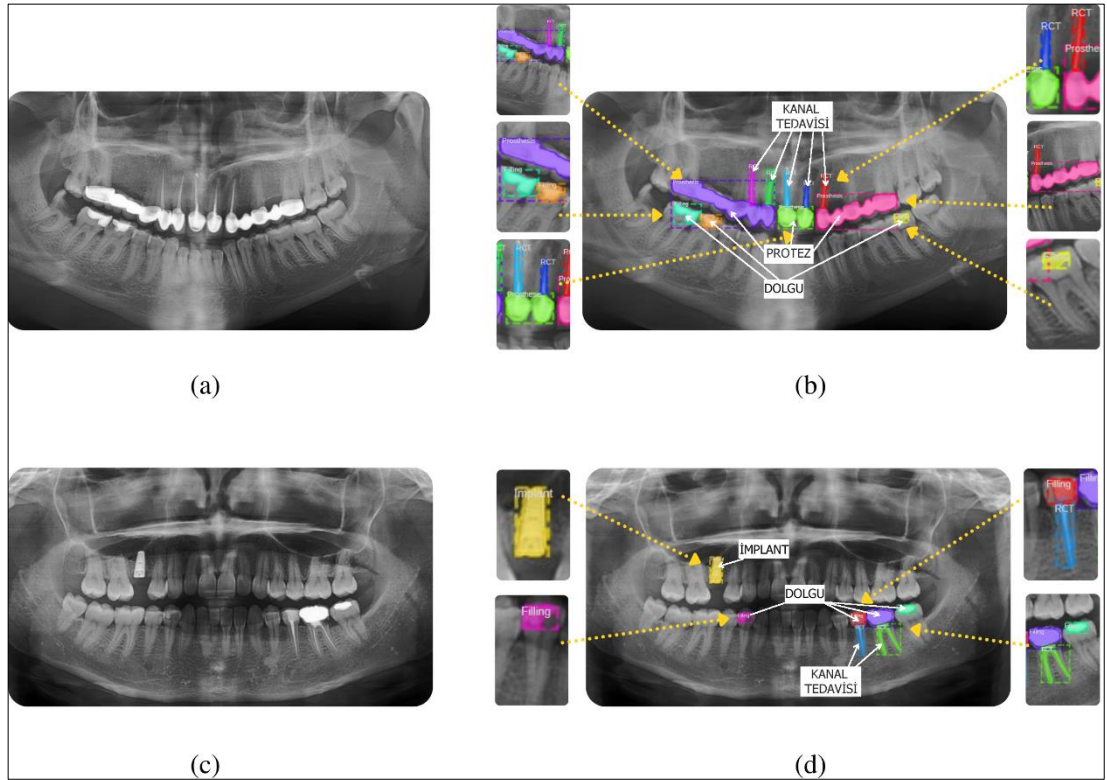
Panoramik radyografilerde restorasyonların tespiti için bölgesel bazlı tespit yaklaşımı izlenmiştir. Mask R-CNN, oldukça gelişmiş bir nesne algılama yöntemidir. Çalışma, tamamen derin nöral katmanlar üzerinde çalışan tam otomatik bir destek sistemi ile kanal tedavisi, protez, dolgu ve implant restorasyon sınıflarının tespit edilmesini ve segmentasyonunu gerçekleştirmiştir. Ayrıca restorasyonların yerleri ve maskeleri eş

zamanlı olarak çıkarılarak diş hekimliği alanında önemli bir dental analiz çalışması yapılmıştır.

#### 4.2.1. Veri Setinin Hazırlanması

Radyograflar, tüp voltajı 60-80 kV, tüp akımı 6-12 mA olan panoramik bir radyografi (I-Max touch, Owandy Radiology, Fransa) kullanılarak çekilmiştir.

Bu çalışmada kullanılan veri seti isim, yaş, cinsiyet gibi kişisel bilgiler olmaksızın anonimleştirilmiş olarak Karabük Eğitim ve Araştırma Hastanesi Ağız ve Diş Sağlığı Merkezi arşivinden alınmıştır.



Şekil 4.7. Orijinal radyografik görüntüler ve etiketlenmiş nesnelere. (a) ve (c) radyograflardaki orijinal girdi örnekleri, (b) ve (d) uzmanlar tarafından etiketlenen görüntüler için temel gerçeklik verileri.

Veri hazırlama ve etiketleme, sınıflandırma çalışmalarında önemli bir adımdır. Veriler aynı dijital cihazdan alındığı için kontrast, çözünürlük gibi farklılıkları ortadan kaldıracak şekilde verilere bir ön işleme işlemi uygulanmamıştır. Verilerin

etiketlenmesi sırasında uzmanların her görüntüyü inceleyip etiketleyebileceği DentiAssist [58] yazılımı kullanılmıştır. Restorasyon içeren her nesne için dış sınırlarına noktalar yerleştirilerek bir poligon şekli oluşturulur ve nokta koordinatları, sınırlayıcı kutu koordinatları ve dış restorasyon bilgileri Şekil 4.7’de gösterildiği gibi kaydedilir.

Çalışmada kullanılan sınıflar arka plan (BG), dolgu, kanal tedavisi, protez ve implant sınıflarından oluşmaktadır. 1569 eğitim görüntüsü 5481 dolgu, 953 protez, 2457 kanal tedavisi ve 300 implant nesnesi içermektedir. 340 doğrulama görüntüsü 1248 dolgu, 341 protez, 629 kanal tedavisi ve 42 implant nesnesi içerir. Modelin eğitiminde her sınıfa ait nesne sayısının doğal dağılıma göre alınmasının daha iyi sonuçlar vereceği sonucuna varılmıştır.

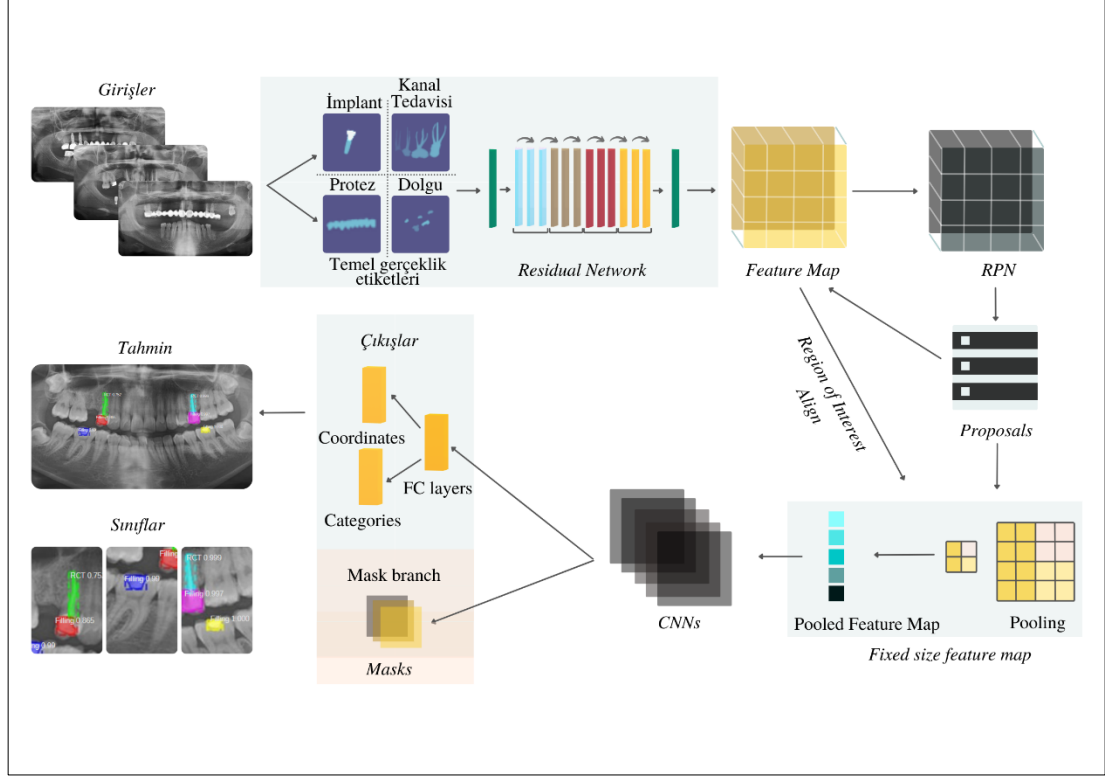
Modelin yeni veriler üzerindeki başarısı, modele KÇD uygulanarak tahmin edilmiştir. Çapraz doğrulama çalışması için veri seti rastgele karıştırılmıştır ve veri seti 5 gruba ayrılmıştır. Daha sonra her kat için seçilen grup, doğrulama seti olarak kullanılmış ve eğitim seti eğitilerek model değerlendirilmiştir.

#### 4.2.2. Model

Çapa içeren CNN, piramit şeklindeki özellikleri kullanarak bölge tabanlı algılama sağlar. R-CNN, RPN’yi Özellik Piramit Ağı (FPN) [35] aracılığıyla  $n \times n$  boyutlu kayan pencerelere yerleştirilerek nesne algılamadaki örnek bölümlenme sonuçlarını iyileştirir. Faster R-CNN, her nesne için ofset çıktılar, çıktı olarak bir sınıf etiketi ve bir sınırlayıcı kutu üretir ve Mask R-CNN ek olarak, tahmin maskesi adı verilen bir nesne maskesi çıktısı verir. Mask R-CNN, örnek bölümlenme görevini [36] gerçekleştirmek için bir özellik çıkarıcı olarak işlev gören standart bir CNN olan evrişimli ağların bir uzantısını içerir. Derin artık ağlar gibi görüntü özelliklerini çıkaran bir ağ, omurga ağı olarak tercih edilir.

ImageNet [38] veri setinde 152 katmana kadar artık ağlar değerlendirilmiş ve ResNet-101 kullanılmıştır. Eğitimin başlatılması için MS COCO [100] ağırlıkları kullanılmıştır. Panoramik diş röntgenlerinde kanal tedavisi, implant, dolgu ve protez

dental restorasyon sınıflarına ayrılan nesnelere, Şekil 4.8’de gösterildiği gibi bir RPN’den geçirilmiştir.



Şekil 4.8. Dişlerin restorasyonlarını tespit eden derin sinir ağı mimarisinin iş akışı.

Bir regresör ve bir sınıflandırıcı içeren bu ağ yaklaşımı, softmax sınıflandırıcı ile teklifin olasılığını belirler ve tekliflerin koordinatlarını regresyon ile verir. RPN ile eş zamanlı olarak FPN sonucu elde edilen diş görüntülerinin özellikleri haritalanarak havuzlama katmanına aktarılır. Çakışan sınır kutuları, ilk adım olarak en yüksek teklif puanına sahip pencereleri temel alan NMS algoritması ile filtrelenir. Havuzlama katmanında seçilen maksimum değerler CNN’ye aktarılır. Diş görüntülerinde ağın çıktısı olarak ROI’nin sınırlayıcı kutusu ve maskesi elde edilir.

#### 4.2.3. Modelin Eğitimi

Model, deneysel çalışmalar için önceki bölümlerde verilen sistem özellikleri, geliştirme ortamı ile parti boyutu 1, öğrenme oranı 0,001 ve epok başına adım sayısı 100 olacak şekilde 800 epok eğitildi.

## BÖLÜM 5

### DENEYSEL ÇALIŞMALAR

Bu bölüm kapsamında iki farklı çalışmanın sonuçları verilmektedir. Birinci çalışmada dişlerin tespit edilmesi ve numaralandırılması ile ilgili sonuçlar sunulurken, ikinci çalışmada ise dişlerdeki restorasyonların tespiti ile ilgili sonuçlar sunulmuştur.

#### 5.1. DİŞLERİN NUMARALANDIRILMASI

Model eğitimi, her çapraz doğrulama katı için 400 epok olacak şekilde doğrulama kaybı değerlerine göre değerlendirilmiştir. Çizelge 5.1'de K katındaki en düşük doğrulama kaybı değerine göre en iyi epok, kesinlik, geri çağırma ve F1-puanı değerleri gösterilmektedir.

Çizelge 5.1. KÇD (K=5) ile verilerin değerlendirilmesi.

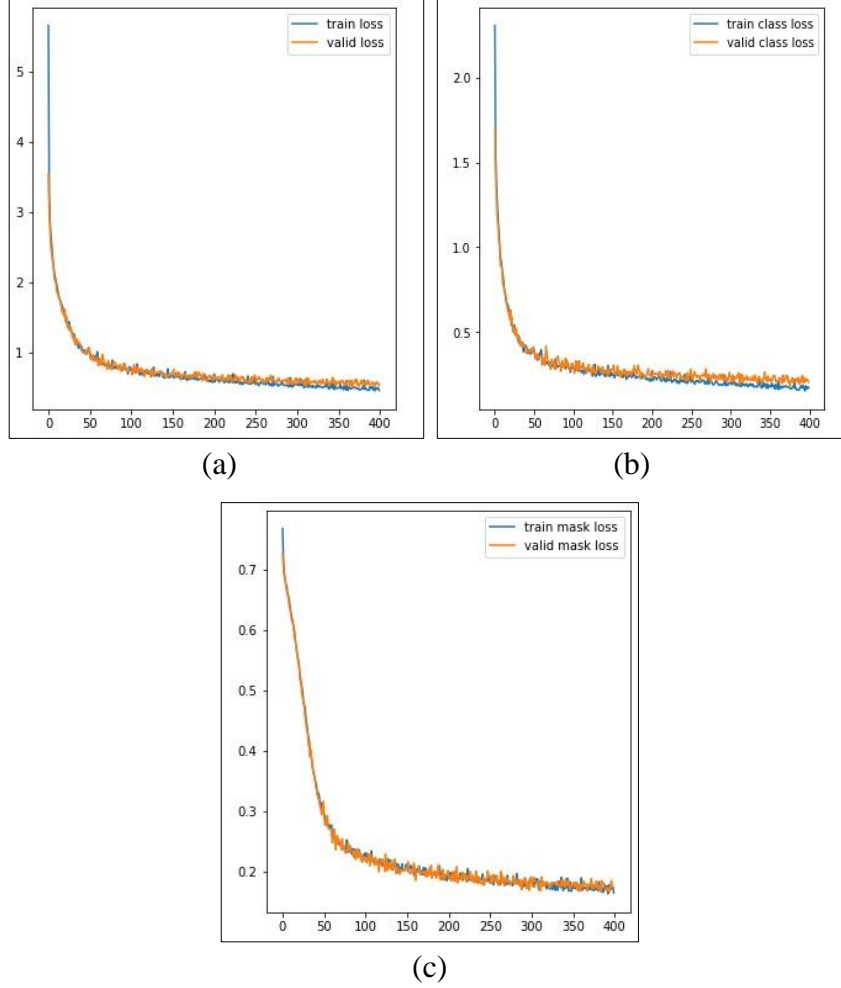
Kat	En İyi Epok	Doğrulama Kaybı	Kesinlik (%)	Duyarlılık (%)	F1-Puanı (%)
1	309	0,5356	92,63	91,78	92,20
2	398	0,5125	92,58	92,03	92,30
3	389	0,5201	95,17	95,40	95,28
4	392	0,5255	93,28	92,86	93,07
5	368	0,5032	92,98	92,93	92,95
<b>Ortalama</b>		<b>0,5194</b>	<b>93,33</b>	<b>93,00</b>	<b>93,16</b>

Çizelge 5.1'de gösterildiği gibi 5. kattaki 368. epok, en düşük doğrulama kaybı değerine sahip olmuştur. Deneysel çalışmalar bu katın sonunda oluşan model dosyası ile gerçekleştirilmiştir.

Çizelge 5.2. Kullanılan algoritmaların karşılaştırılması.

Yapı	mAP(IOUS=0,5) (%)	Kesinlik (%)	Duyarlılık (%)	F1-Puanı (%)
Mask R-CNN	89,0	92,21	91,94	92,07
Mask R-CNN + Sezgisel Algoritma	93,0	96,08	95,65	95,87

Bu çalışmanın ardından önerilen sezgisel bir yaklaşım ile derin öğrenme algoritmasının sonuçları geliştirilmiştir. Temel modelin ve sezgisel algoritmanın sonuçları Çizelge 5.2’de gösterilmektedir.



Şekil 5.1. KÇD için en iyi tur dönemi kayıp değerleri. (a) Genel kayıp grafiği. (b) Sınıf kaybı grafiği. (c) Maske kaybı grafiği.

Şekil 5.1’de KÇD işleminde en düşük kayıp değerini veren 5 numaralı katın genel kayıp, sınıf kaybı ve maske kayıp grafikleri gösterilmektedir. Grafikten de anlaşılacağı üzere kayıp değerleri 400. epoka yaklaştığında en düşük değerlerine ulaşmaktadır.

Çizelge 5.3, tüm diş sınıflarının performans sonuçlarını göstermektedir. Burda FDI diş numaralandırma sistemine göre ağız üst bölgesi dişlerinden başlayacak şekilde her bir diş için test kümesindeki görsellerin sonuçları doğru pozitif (DP), yanlış pozitif (YP),


yanlış negatif (YN) değerleri ile kesinlik, duyarlılık ve F1-puanı ölçümleri ile gösterilmiştir.

Çizelge 5.3. Diş sınıflarına göre performans sonuçları.


Diş Numarası	DP	YP	YN	Kesinlik (%)	Duyarlılık (%)	F1-Puanı (%)
18	243	29	24	89,34	91,01	90,17
17	369	42	31	89,78	92,25	91,00
16	315	14	33	95,74	90,52	93,06
15	367	25	15	93,62	96,07	94,83
14	375	11	34	97,15	91,69	94,34
13	424	4	16	99,07	96,36	97,70
12	428	8	9	98,17	97,94	98,05
11	443	8	4	98,23	99,11	98,66
21	439	5	7	98,87	98,43	98,65
22	428	8	7	98,17	98,39	98,28
23	436	7	9	98,42	97,98	98,20
24	374	12	26	96,89	93,50	95,17
25	375	17	12	95,66	96,90	96,28
26	323	10	26	97,00	92,55	94,72
27	378	31	27	92,42	93,33	92,87
28	272	23	13	92,20	95,44	93,79
38	280	13	16	95,56	94,59	95,08
37	366	21	23	94,57	94,09	94,33
36	298	17	10	94,60	96,75	95,67
35	407	11	2	97,37	99,51	98,43
34	434	9	13	97,97	97,09	97,53
33	456	4	8	99,13	98,28	98,70
32	442	20	14	95,67	96,93	96,30
31	418	24	34	94,57	92,48	93,51
41	412	16	37	96,26	91,76	93,96
42	440	12	19	97,35	95,86	96,60
43	449	11	15	97,61	96,77	97,19
44	429	12	12	97,28	97,28	97,28
45	411	15	4	96,48	99,04	97,74
46	292	17	10	94,50	96,69	95,58
47	369	23	27	94,13	93,18	93,65
48	266	16	15	94,33	94,66	94,49

Şekil 5.2, önerilen sezgisel yaklaşımın test veri setindeki sonuçlarının dişlere göre doğruluk grafiğini, Şekil 5.2, karmaşıklık matrisini göstermektedir. Sonuçların daha net görüntülenmesi için alt ve üst çenedeki dişler iki ayrı grafiğe ve matrise ayrılmıştır.

Çizelge 5.3 ve karmaşıklık matrisi incelendiğinde dişlerin ağız içinde orta bölgede olanlarında (11,21,31,41) doğru tespit oranının yüksek olduğu, ağız içinin arkalarına doğru gidildikçe (18,28,38,48) doğru tespit sayılarında düşüş olduğu açıkça görülmektedir.

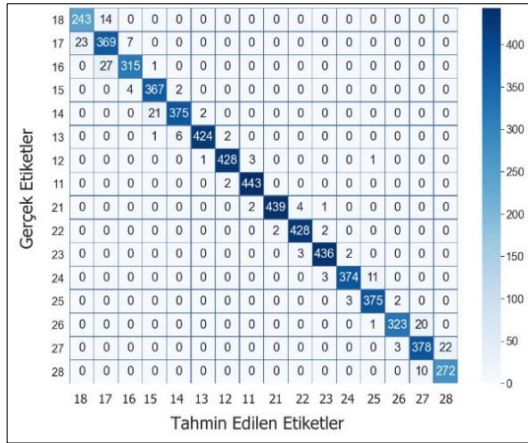


(a)

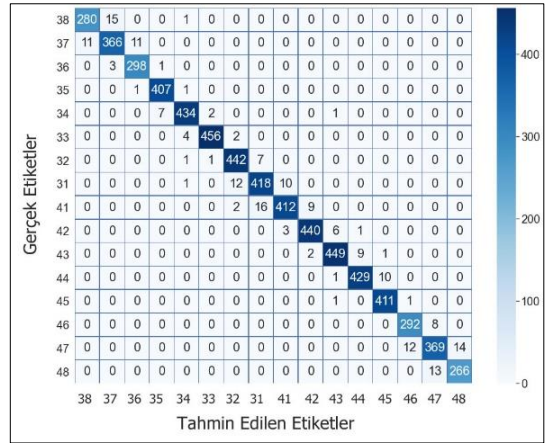


(b)

Şekil 5.2. Dişlerin performans metrikleri grafiği. (a) Üst dişlerin performans metrikleri. (b) Alt dişlerin performans metrikleri.



(a)




(b)


Şekil 5.3. Diş numaralandırmada sezgisel algoritma sonucunun karmaşıklık matrisi. (a) Üst dişlerin karmaşıklık matrisi. (b) Alt dişlerin karmaşıklık matrisi.

Test veri seti içerisinde seçilmiş tam dişli ve Mask R-CNN model sonucundaki numaralandırma işleminde bir yada daha fazla diş üzerinde çakışan numaralandırma olan görüntüde (Şekil 5.4), eksik diş olan ve Mask R-CNN model sonucu numaralandırma işleminde bir yada daha fazla diş üzerinde çakışan numaralandırma bulunan görüntüde (Şekil 5.5), eksik diş olan ve ve Mask R-CNN model sonucu numaralandırma işleminde bir yada daha fazla diş üzerinde numaralandırma hatası bulunan görüntüde (Şekil 5.6), uzmanlar tarafından etiketlenen temel gerçek görüntüsü, Mask R-CNN model sonucu ve geliştirilen sezgisel yaklaşımın belirtilen hataları düzeltmesi açıkça görülmektedir.






(a)




(b)

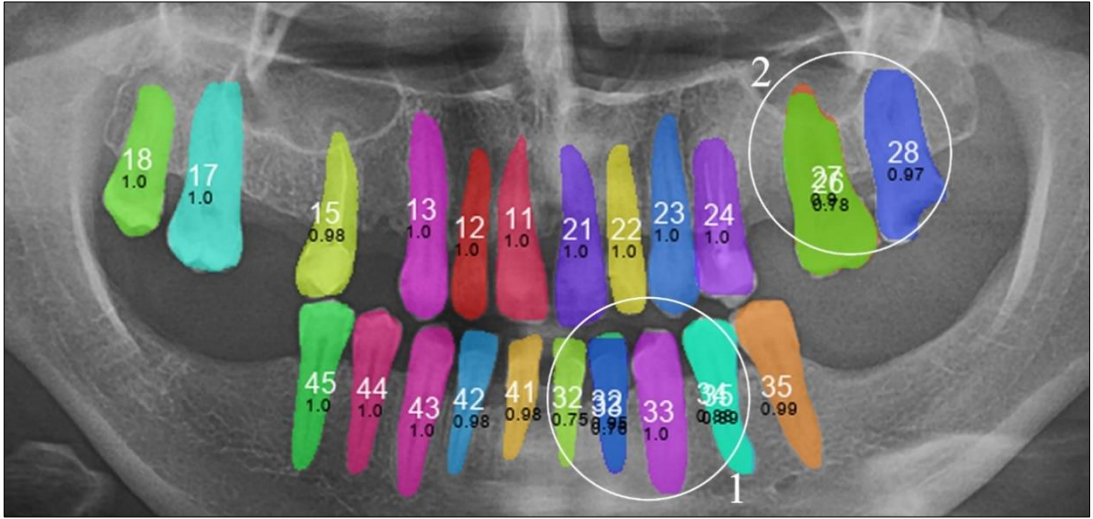


(c)


Şekil 5.4. Tam dişli ve çakışan numaralama olan görüntüde örnek sonuç. (a) Temel gerçeklik. (b) Mask R-CNN Sonucu. (c) Sezgisel algoritma ile iyileştirme.



(a)




(b)




(c)

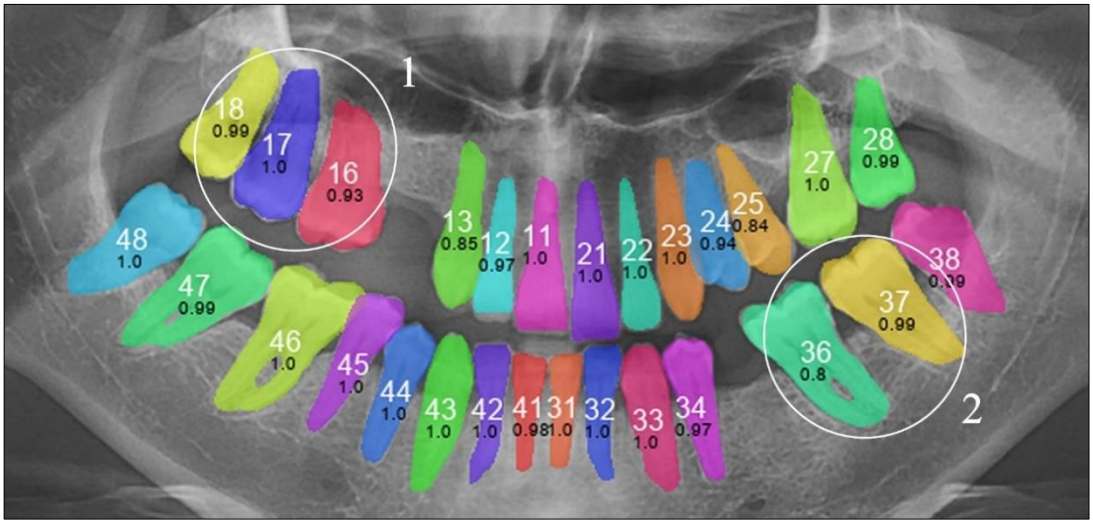
Şekil 5.5. Eksik diş ve çakışan numaralama olan görüntüde örnek sonuç. (a) Temel gerçeklik. (b) Mask R-CNN Sonucu. (c) Sezgisel algoritma ile iyileştirme.



(a)



(b)



(c)

Şekil 5.6. Eksik diş olan ve sıralama hatası olan görüntüde örnek sonuç. (a) Temel gerçeklik. (b) Mask R-CNN sonucu. (c) Sezgisel algoritma ile iyileştirme.

## 5.2. DIŐLERDEKİ RESTORASYONLARIN TESPİT EDİLMESİ

Bu çalışmada dental radyologlar tarafından oluşturulan etiketler ile her bir dental restorasyon nesnesini tespit ederek segmentasyon görevi gerçekleştirilmiştir. Panoramik radyografilerde restorasyonların tespiti için bölgesel bazlı tespit yaklaşımı izlenmiştir.

Modelin yeni veriler üzerindeki başarısı, modele KÇD uygulanarak ölçülmüştür. Çapraz doğrulama çalışması için veri seti rastgele karıştırılmış ve 5 gruba ayrılmıştır. Daha sonra her kat için seçilen grup doğrulama seti olarak kullanılmış ve eğitim seti kullanılarak model kurulmuş ve doğrulama seti ile değerlendirilmiştir. Modelin daha önce karşılaşmadığı veriler üzerindeki davranışını ve performansını KÇD yöntemiyle ölçen Çizelge 5.4'te gösterilen sonuçlara göre her bir turun ortalamasından elde edilen değerler modelin performans sonuçlarından uzak değildir.

Çizelge 5.4. KÇD (K=5) sonuç tablosu ile verilerin değerlendirilmesi.

Tur	Kesinlik (%)	Duyarlılık (%)	F1-Puanı (%)
1	89,66	87,49	88,57
2	90,13	84,87	87,42
3	77,24	75,44	76,33
4	80,57	72,71	76,44
5	78,02	77,26	77,64
<b>Ortalama</b>	<b>83,12</b>	<b>79,56</b>	<b>81,28</b>


Görüntüler bitmap formatındadır ve boyut çeşitliliğine sahiptir. Panoramik radyografiler, Mask R-CNN mimarisine uyumlu olacak şekilde yeniden boyutlandırılarak 1024 x 1024 piksel değerlerine sabitlenmiştir. Ağın performansı değerlendirilirken Şekil 5.7'deki karmaşıklık matrisinden elde edilen doğru pozitif, yanlış pozitif ve yanlış negatif değerlerinden yararlanılmıştır. Çizelge 5.5, karmaşıklık matrisinde görselleştirilen değerler kullanılarak hesaplanan kesinlik, duyarlılık, F1-puanı ve mAP metriklerinin sırasıyla %93,54, %84,51, %88,80 ve %82,31 olarak ölçüldüğünü göstermektedir.

Çizelge 5.5 incelendiğinde modelin implant sınıfında yüksek doğruluk elde ettiği görülmektedir. Bunun nedeni implant sınıfının diğer sınıflara göre benzersiz ve kolay


ayrıt edilebilir bir yapısının olmasıdır. Model, dolgu sınıfının belirli bir şeklinin olmayışı ve bazı görüntülerde renk yoğunluğunun arka plan renklerine yakın olmasından dolayı dolgu sınıfı için diğer sınıflara göre daha düşük performans değerleri üretmiştir.

Çizelge 5.5. Segmentasyon modelinin performans metrikleri.


Sınıflar	Keskinlik (%)	Duyarlılık (%)	F1-Puanı (%)
Dolgu	90,63	81,33	85,73
Protez	97,31	95,31	96,30
Kanal Tedavisi	96,71	84,10	89,97
İmplant	100,00	97,62	98,80
<b>Ortalama</b>	<b>93,54</b>	<b>84,51</b>	<b>88,80</b>




Şekil 5.7. Restorasyon sınıflandırma sonuçlarının karmaşıklık matrisi.




(a)



(b)



(c)



(d)

Şekil 5.8. Temel gerçek ve segmentasyon sonuçlarıyla görselleştirilen farklı sınıf örnekleri. A ve C, uzmanlar tarafından etiketlenmiş gerçek görüntülerdir. B ve D, modelin tahmin sonuçlarıdır.

Şekil 5.8’de panoramik görüntülerin uzman radyologlar tarafından etiketlenmiş hali ve geliştirilen modelin tahmin sonucu oluşan görüntüler örnek olarak verilmiştir. Model tam diş olan ve eksik diş olan görüntülerde de dolgu, kanal tedavisi, implant ve protez restorasyonlarını doğru bir şekilde tespit edip segmentasyonu gerçekleştirmiştir.

## BÖLÜM 6

### SONUÇLAR VE ÖNERİLER

Panoramik görüntülerde, önerilen derin öğrenme ve sezgisel yaklaşımlı karar destek sistemi, diş numaralandırmada büyük doğruluk göstermiştir. Sezgisel yaklaşımın yüksek doğruluk elde etmedeki katkısı oldukça etkilidir. Elde edilen yüksek doğruluğa rağmen model ve sezgisel yaklaşım sonuçlarında hatalı numaralandırmalar da bulunmaktadır. Buna rağmen panoramik radyografilerde dişlerin tespiti ve numaralandırılmasında temel modelin sonuçları sezgisel yaklaşım ile %4 kadar iyileştirilerek önerilen yöntemin doğruluğu %96,08 kesinlik değerine ulaşmıştır.

Dişlerdeki restorasyonların segmentasyonu için önerilen karar destek sisteminde bölge bazlı segmentasyon yöntemlerine yer veren Mask R-CNN algoritması kullanılarak diş restorasyon segmentasyonunda etkin sonuçlar elde edilmiştir. Çalışma, test aşamasında gerçek hayattaki verilere dayalı tespitin yapay zekâ yardımıyla daha kesin ve hızlı sonuçlar üretebileceğini doğrulamıştır. Panoramik radyografilerde dolgu, protez, kanal tedavisi ve implant sınıfları tespit edilmiş ve poligonlarla çalışan model diş restorasyonlarının segmentasyonunda %93,54 kesinlik değerine ulaşmıştır.

Çalışmada önerilen karar destek sistemi, dişlerin numaralandırılması ile diş tedavilerinin panoramik radyografilerde tespit edilmesi için umut verici bir araçtır. Bu model, diş kayıtlarının otomatik olarak tespit edilmesine ve analiz edilmesine yardımcı olarak uzmanların iş yükünü azaltacaktır. Gelecekteki çalışmalarda, numaralandırma doğruluğunu daha üst düzeye çıkarmak ve temel gerçek ile tam tutarlı numaralandırma sonuçları elde etmek için sezgisel yaklaşımın daha da geliştirilmesi gerekmektedir. Ek olarak, bunun gibi sonuçlar diş radyologlarının yapay zekâyı kabul etmesine, geliştirmesine ve kullanmasına yardımcı olabilir. İleriki çalışmalarda dişlerdeki restorasyonlardan olan implant sınıflarının tiplerine odaklanılarak tespit gerçekleştirilebilir. Ayrıca farklı implant markalarının tespit sonuçları ile implant

üreticilerine bilgi verilebilmektedir. Bu çalışma periapikal, bitewing ve sefalometrik gibi teşhis için gerekli olan diğer radyografik görüntü tiplerinde diş tiplerinin saptanmasını sağlayarak genel bir kayıt sisteminin geliştirilmesi için umut verici bir temel oluşturmaktadır.

Çizelge 6.1. Panoramik görüntülerde diş numaralandırma çalışmaları.

Çalışmalar	Kullanılan Yöntemler	Segmentasyon	Performans Ölçümleri
Tuzoff vd. [37]	Faster R-CNN VGG-16 Sezgisel yaklaşım		Hassasiyet %98,00 Özgüllük %99,00
Kim vd. [40]	DeNTNet		F1-Puanı %75,00
Kim vd. [41]	R-CNN Sezgisel yaklaşım		Hassasiyet %84,20 Özgüllük %75,50 Doğruluk %84,5
Silva vd. [42]	PANet	Var	mAP %74,00
Mahdi vd. [53]	Faster R-CNN Optimizasyon		mAP %98,10 F1-Puanı %98,20
Bilgir vd. [47]	Faster R-CNN		Hassasiyet %95,60 Kesinlik %96,50 F1-Puanı %96,10
Lin vd. [51]	ResNet		Doğruluk %95,60
Privado vd. [52]	Mask R-CNN		Doğruluk %93,80
Estai vd. [46]	U-Net R-CNN VGG-16		Kesinlik %98,00 Duyarlılık %98,00 F1-Puanı %98,00
Akkaya [54]	YOLO V4		mAP %92,22
Chandrashekar vd. [55]	Mask R-CNN Faster R-CNN	Var	mAP %97,30 Doğruluk %98,77 F1-Puanı %98,83
Önerilen çalışma	Mask R-CNN Sezgisel yaklaşım	Var	mAP %92,49 Kesinlik %96,08 Duyarlılık %95,65 F1-Puanı %95,87

Temel derin öğrenme modelinin diş numaralandırma performansı, bu çalışmada önerilen sezgisel bir yöntem kullanılarak iyileştirilmiştir. Mask R-CNN ve sezgisel yaklaşım kullanılan çalışmada, PANet gibi bölütleme algoritmaları kullanılarak yapılan diş numaralandırma çalışmalarından daha iyi sonuçlar vermektedir.

Çizelge 6.1’de yer alan panoramik görüntülerde diş numaralandırma çalışmaları incelendiğinde önerilen yöntemlerde CNN tabanlı algoritmaların kullanıldığı görülmektedir. Panoramik radyografların dental radyologlar için diğer görüntüleme yöntemlerine göre birçok avantaja sahip olmasının bir sonucu olarak klinik



çalıřmalarda teřhis ve tedavi iin olduka fazla tercih edilmesi ve buna baėlı olarak eldeki grnt sayısının fazla olması bu alıřmalarda byk lde panoramik grntlerin kullanılmasına neden olmuřtur. Sonular, Mask R-CNN tabanlı bir diř tespit grevi gerekleřtirdikten sonra sezgisel bir yntem kullanmanın, kalıcı diřleri tespit etmede ve numaralandırmada bir diř hekiminki kadar doėru performansla sonulandıėını gstermiřtir. alıřma sonuları izelge 6.1'de yer alan nceki alıřmaların sonuları ile karřılařtırıldıėında, nerilen yntemin numaralandırma konusunda Mask R-CNN ve sezgisel algoritmadan daha iyi performans gsterdiėi aıka grlmektedir.

Silva vd. [42] farklı modellerle yaptıkları segmentasyon ve diř numaralandırma alıřmasında en iyi sonuları elde etmek iin PANet'i kullanmıřlardır. PANet numaralandırmada %74,00 mAP deėerine ulařmıřtır. Mask R-CNN ve sezgisel yaklařım kullanılan alıřmada numaralandırmada %92,49 mAP deėerine ulařılmıřtır.

Chandrashekar vd. [55] Mask R-CNN ve Faster R-CNN modellerini birleřtirmiřtir. Bu yntem yksek bir hesaplama maliyetine neden olmaktadır. Bu maliyet ise iřlem sresini artırmaktadır. alıřmada birincil model ile sezgisel bir yaklařım kullanılarak iřlemler daha hafif ve hızlı hale getirilmiřtir.

Akkaya vd [54] tespit ve numaralandırma alıřmalarında pediatrik panoramik radyograflar kullanmıřlardır. FDI gsteriminde yer alan kalıcı diřler pediatrik panoramik radyograflarda bulunmamaktadır. nerilen yntemde alıřma yetiřkin panoramik radyografları ile yapıldıėı iin tm kalıcı diřlerin tespiti, segmentasyonu ve numaralandırılması yapılabilmektedir.

alıřmada mAP deėerinde yksek sonular elde edilmiřtir. Ancak literatrde kesinlik, geri aėırma ve F1-puanı aısından daha iyi performans gsteren alıřmalar mevcuttur. Bu durumun sebebi alıřmadaki rnek segmentasyonu iřleminin gerekleřtirilmesidir. Diėer alıřmalar incelendiėinde rnek segmentasyonu yapılmadan numaralandırma grevinin gerekleřtirildiėi grlmektedir. Segmentasyon iřlemi diėerlerine gre daha zordur. nk segmentasyon iřlemi sırasında tm diřler arka plandan ayrılır. Kenarlardan bařlayarak diřlerin daha belirgin

görünmesini sağladığı için daha kesin sonuçlar verir. Bu yöntem kullanıcılar için daha kullanışlıdır.

Dental radyologlara zaman kazandırarak ve manuel programlamayı azaltarak, günlük uygulamada, klinik uygulamada, tedavi süreçlerinde ve dişhekimliği eğitiminde derin öğrenmenin kullanılması, diş hekimliği muayenelerinde, araştırma ve üniversite eğitim laboratuvarlarında iş akışı verimliliği üzerinde doğrudan bir etkiye sahip olacaktır. Ancak, derin öğrenme sistemini klinik uygulamaya dönüştürmek için daha fazla çalışmaya ihtiyaç vardır.

## KAYNAKLAR

1. Chollet, F., “Python Ile Derin Öğrenme”, Buzdağı Yayınevi, 1–52 (2019).
2. Szegedy, C., Toshev, A., and Erhan, D., “Deep Neural Networks for Object Detection”, *Advances In Neural Information Processing Systems 26 (NIPS 2013)*, (2013).
3. Lecun, Y., Bengio, Y., and Hinton, G., “Deep learning”, *Nature 2015 521:7553*, 521 (7553): 436–444 (2015).
4. Girshick, R., Donahue, J., Darrell, T., and Malik, J., “Rich feature hierarchies for accurate object detection and semantic segmentation”, *Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition (CVPR)*, 580–587 (2014).
5. Girshick, R., “Fast R-CNN”, *IEEE International Conference On Computer Vision*, 1440–1448 (2015).
6. Ren, S., He, K., Girshick, R., and Sun, J., “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks”, *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 39 (6): 1137–1149 (2017).
7. He, K., Gkioxari, G., Dollar, P., and Girshick, R., “Mask R-CNN”, *Proceedings Of The IEEE International Conference On Computer Vision*, 2017-Octob: 2980–2988 (2017).
8. Zanjani, F. G., Pourtaherian, A., Zinger, S., Moin, D. A., Claessen, F., Cherici, T., Parinussa, S., and de With, P. H. N., “Mask-MCNet: Tooth instance segmentation in 3D point clouds of intra-oral scans”, *Neurocomputing*, 453: 286–298 (2021).
9. Hallikainen, D., “History of panoramic radiography”, *Acta Radiologica*, 37 (3 PART 2): 441–445 (1996).
10. Bozkurt, M. H. and Karagol, S., “Jaw and Teeth Segmentation on the Panoramic X-Ray Images for Dental Human Identification”, *Journal Of Digital Imaging*, 33 (6): 1410–1427 (2020).
11. Terry, G. L., Noujeim, M., Langlais, R. P., Moore, W. S., and Prihoda, T. J., “A clinical comparison of extraoral panoramic and intraoral radiographic modalities for detecting proximal caries and visualizing open posterior interproximal contacts”, *Dentomaxillofacial Radiology*, 45 (4): 450–459 (2016).

12. Kim, Y. H., Ha, E. G., Jeon, K. J., Lee, C., and Han, S. S., “A fully automated method of human identification based on dental panoramic radiographs using a convolutional neural network”, *Dento Maxillo Facial Radiology*, 51 (4): 20210383 (2022).
13. Ariji, Y., Yanashita, Y., Kutsuna, S., Muramatsu, C., Fukuda, M., Kise, Y., Nozawa, M., Kuwada, C., Fujita, H., Katsumata, A., and Ariji, E., “Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique”, *Oral Surgery, Oral Medicine, Oral Pathology And Oral Radiology*, 128 (4): 424–430 (2019).
14. Jader, G., Fontineli, J., Ruiz, M., Abdalla, K., Pithon, M., and Oliveira, L., “Deep Instance Segmentation of Teeth in Panoramic X-Ray Images”, *Proceedings - 31st Conference On Graphics, Patterns And Images, SIBGRAPI 2018*, 400–407 (2019).
15. Ohashi, Y., Ariji, Y., Katsumata, A., Fujita, H., Nakayama, M., Fukuda, M., Nozawa, M., and Ariji, E., “Utilization of computer-aided detection system in diagnosing unilateral maxillary sinusitis on panoramic radiographs”, *Dentomaxillofacial Radiology*, 45 (3): (2016).
16. Karaoglu, A., Ozcan, C., Pekince, A., Yasa, Y., Tekin, B. Y., and Ozdemir, D., “Automatic Dental Segmentation Module Supported by Artificial Intelligence for Dentistry Students Education”, *Artificial Intelligence Theory And Applications*, 1 (Nisan): 180–190 (2021).
17. El-Baz, A., Beache, G. M., Gimel’Farb, G., Suzuki, K., Okada, K., Elnakib, A., Soliman, A., and Abdollahi, B., “Computer-aided diagnosis systems for lung cancer: Challenges and methodologies”, *International Journal Of Biomedical Imaging*, 2013: (2013).
18. Hung, K., Montalvao, C., Tanaka, R., Kawai, T., and Bornstein, M. M., “The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review”, *Dentomaxillofacial Radiology*, 49 (1): 49 (2019).
19. Joda, T., Yeung, A. W. K., Hung, K., Zitzmann, N. U., and Bornstein, M. M., “Disruptive Innovation in Dentistry: What It Is and What Could Be Next”, *Https://Doi.Org/10.1177/0022034520978774*, 100 (5): 448–453 (2020).
20. Yaren Tekin, B., Yasa, Y., Ozcan, C., Karaoglu, A., Pekince, A., Cilek, S., Ozdemir, D., and Meseci, E., “Tooth Detection and Numbering with Instance Segmentation in Panoramic Radiographs”, *1 St International Conference On Interdisciplinary Applications Of Artificial Intelligence (ICIDAAI’21)*, 96–99 (2021).
21. Amer, Y. Y. and Aqel, M. J., “An Efficient Segmentation Algorithm for Panoramic Dental Images”, *Procedia Computer Science*, 65: 718–725 (2015).

22. Silva, G., Oliveira, L., and Pithon, M., “Automatic segmenting teeth in X-ray images: Trends, a novel data set, benchmarking and future perspectives”, *Expert Systems With Applications*, 107: 15–31 (2018).
23. Wirtz, A., Mirashi, S. G., and Wesarg, S., “Automatic Teeth Segmentation in Panoramic X-Ray Images Using a Coupled Shape Model in Combination with a Neural Network”, *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 11073 LNCS: 712–719 (2018).
24. Koch, T. L., Perslev, M., Igel, C., and Brandt, S. S., “Accurate segmentation of dental panoramic radiographs with u-NETS”, *Proceedings - International Symposium On Biomedical Imaging*, 2019-April: 15–19 (2019).
25. Ronneberger, O., Fischer, P., and Brox, T., “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: 234–241 (2015).
26. Muresan, M. P., Barbura, A. R., and Nedevschi, S., “Teeth Detection and Dental Problem Classification in Panoramic X-Ray Images using Deep Learning and Image Processing Techniques”, *Proceedings - 2020 IEEE 16th International Conference On Intelligent Computer Communication And Processing, ICCP 2020*, 457–463 (2020).
27. Redmon, J., Divvala, S., Girshick, R., and Farhadi, A., “You Only Look Once: Unified, Real-Time Object Detection”, *Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition (CVPR)*, 779–788 (2016).
28. Lee, J. H., Han, S. S., Kim, Y. H., Lee, C., and Kim, I., “Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs”, *Oral Surgery, Oral Medicine, Oral Pathology And Oral Radiology*, 129 (6): 635–642 (2020).
29. Oktay, A. B., “Tooth detection with Convolutional Neural Networks”, *2017 Medical Technologies National Conference, TIPTEKNO 2017*, 2017-January: 1–4 (2017).
30. Krizhevsky, A., Sutskever, I., and Hinton, G. E., “ImageNet classification with deep convolutional neural networks”, *Communications Of The ACM*, 60 (6): 84–90 (2017).
31. Shaheen, E., Leite, A., Alqahtani, K. A., Smolders, A., van Gerven, A., Willems, H., and Jacobs, R., “A novel deep learning system for multi-class tooth segmentation and classification on cone beam computed tomography. A validation study”, *Journal Of Dentistry*, 115: 103865 (2021).
32. Shelhamer, E., Long, J., and Darrell, T., “Fully Convolutional Networks for Semantic Segmentation”, *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 39 (4): 640–651 (2014).

33. Chung, M., Lee, J., Park, S., Lee, M., Lee, C. E., Lee, J., and Shin, Y. G., “Individual tooth detection and identification from dental panoramic X-ray images via point-wise localization and distance regularization”, *Artificial Intelligence In Medicine*, 111: 101996 (2021).
34. Leite, A. F., Gerven, A. van, Willems, H., Beznik, T., Lahoud, P., Gaêta-Araujo, H., Vranckx, M., and Jacobs, R., “Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs”, *Clinical Oral Investigations*, 25 (4): 2257–2267 (2021).
35. Vinayahalingam, S., Goey, R., Kempers, S., Schoep, J., Cherici, T., Moin, D. A., and Hanisch, M., “Automated chart filing on panoramic radiographs using deep learning”, *Journal Of Dentistry*, 115: 103864 (2021).
36. Muramatsu, C., Morishita, T., Takahashi, R., Hayashi, T., Nishiyama, W., Ariji, Y., Zhou, X., Hara, T., Katsumata, A., Ariji, E., and Fujita, H., “Tooth detection and classification on panoramic radiographs for automatic dental chart filing: improved classification by multi-sized input data”, *Oral Radiology*, 37 (1): 13–19 (2021).
37. Tuzoff, D. V., Tuzova, L. N., Bornstein, M. M., Krasnov, A. S., Kharchenko, M. A., Nikolenko, S. I., Sveshnikov, M. M., and Bednenko, G. B., “Tooth detection and numbering in panoramic radiographs using convolutional neural networks”, *Dentomaxillofacial Radiology*, 48 (4): (2019).
38. Simonyan, K. and Zisserman, A., “Very Deep Convolutional Networks for Large-Scale Image Recognition”, *3rd International Conference On Learning Representations, ICLR 2015 - Conference Track Proceedings*, (2014).
39. Chen, H., Zhang, K., Lyu, P., Li, H., Zhang, L., Wu, J., and Lee, C. H., “A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films”, *Scientific Reports*, 9 (1): 1–11 (2019).
40. Kim, J., Lee, H. S., Song, I. S., and Jung, K. H., “DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs”, *Scientific Reports 2019 9:1*, 9 (1): 1–9 (2019).
41. Kim, C., Kim, D., Jeong, H. G., Yoon, S. J., and Youm, S., “Automatic Tooth Detection and Numbering Using a Combination of a CNN and Heuristic Algorithm”, *Applied Sciences 2020, Vol. 10, Page 5624*, 10 (16): 5624 (2020).
42. Silva, B., Pinheiro, L., Oliveira, L., and Pithon, M., “A study on tooth segmentation and numbering using end-to-end deep neural networks”, *2020 33rd SIBGRAPI Conference On Graphics, Patterns And Images (SIBGRAPI)*, 164–171 (2020).
43. Liu, S., Qi, L., Qin, H., Shi, J., and Jia, J., “Path Aggregation Network for Instance Segmentation”, *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, 8759–8768 (2018).

44. Chen, K., Pang, J., Wang, J., Xiong, Y., Li, X., Sun, S., Feng, W., Liu, Z., Shi, J., Ouyang, W., Loy, C. C., and Lin, D., “Hybrid Task Cascade for Instance Segmentation”, *Proceedings Of The IEEE/CVF Conference On Computer Vision And Pattern Recognition (CVPR)*, 4974–4983 (2019).
45. Zhang, H., Wu, C., Zhang, Z., Zhu, Y., Lin, H., Zhang, Z., Sun, Y., He, T., Mueller, J., Manmatha, R., Li, M., Smola, A., and Davis, U., “ResNeSt: Split-Attention Networks”, *Proceedings Of The IEEE/CVF Conference On Computer Vision And Pattern Recognition (CVPR) Workshops*, 2736–2746 (2022).
46. Estai, M., Tennant, M., Gebauer, D., Brostek, A., Vignarajan, J., Mehdizadeh, M., and Saha, S., “Deep learning for automated detection and numbering of permanent teeth on panoramic images”, <https://doi.org/10.1259/dmfr.20210296>, 50: 50 (2021).
47. Bilgir, E., Bayrakdar, İ. Ş., Çelik, Ö., Orhan, K., Akkoca, F., Sağlam, H., Odabaş, A., Aslan, A. F., Ozcetin, C., Kılılı, M., and Rozylo-Kalinowska, I., “An artificial intelligence approach to automatic tooth detection and numbering in panoramic radiographs”, *BMC Medical Imaging*, 21 (1): 1–9 (2021).
48. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z., “Rethinking the Inception Architecture for Computer Vision”, *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, 2016-December: 2818–2826 (2015).
49. Görürgöz, C., Orhan, K., Bayrakdar, I. S., Çelik, Ö., Bilgir, E., Odabaş, A., Aslan, A. F., and Jagtap, R., “Performance of a convolutional neural network algorithm for tooth detection and numbering on periapical radiographs”, <https://doi.org/10.1259/dmfr.20210246>, 50: 20210246 (2021).
50. Kılıc, M. C., Bayrakdar, I. S., Çelik, Ö., Bilgir, E., Orhan, K., Aydın, O. B., Kaplan, F. A., Sağlam, H., Odabaş, A., Aslan, A. F., and Yılmaz, A. B., “Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs”, *Dentomaxillofacial Radiology*, 50 (6): 20200172 (2021).
51. Lin, S.-Y. and Chang, H.-Y., “Tooth Numbering and Condition Recognition on Dental Panoramic Radiograph Images Using CNNs”, *IEEE Access*, 9: 166008–166026 (2021).
52. Prados-Privado, M., García Villalón, J., Blázquez Torres, A., Martínez-Martínez, C. H., and Ivorra, C., “A Convolutional Neural Network for Automatic Tooth Numbering in Panoramic Images”, *BioMed Research International*, 2021: 1–7 (2021).
53. Mahdi, F. P., Motoki, K., and Kobashi, S., “Optimization technique combined with deep learning method for teeth recognition in dental panoramic radiographs”, *Scientific Reports 2020 10:1*, 10 (1): 1–12 (2020).

54. Akkaya, N., Kansu, Ö., Kansu, H., Çağırankaya, L. B., and Arslan, U., “Comparing the accuracy of panoramic and intraoral radiography in the diagnosis of proximal caries”, *Dentomaxillofacial Radiology*, 35 (3): 170–174 (2006).
55. Chandrashekar, G., AlQarni, S., Bumann, E. E., and Lee, Y., “Collaborative deep learning model for tooth segmentation and identification using panoramic radiographs”, *Computers In Biology And Medicine*, 148: 105829 (2022).
56. Yaren Tekin, B., Ozcan, C., Pekince, A., and Yasa, Y., “An enhanced tooth segmentation and numbering according to FDI notation in bitewing radiographs”, *Computers In Biology And Medicine*, 146: 105547 (2022).
57. Karaoglu, A., Ozcan, C., Pekince, A., and Yasa, Y., “Numbering teeth in panoramic images: A novel method based on deep learning and heuristic algorithm”, *Engineering Science And Technology, An International Journal*, 37: 101316 (2023).
58. İnternet: “DentiAssist Veri Etiketleme Platformu”, [app.dentiassist.com](http://app.dentiassist.com) (2023).
59. McCulloch, W. S. and Pitts, W., “A logical calculus of the ideas immanent in nervous activity”, *The Bulletin Of Mathematical Biophysics*, 5 (4): 115–133 (1943).
60. Rosenblatt, F., “The perceptron: A probabilistic model for information storage and organization in the brain”, *Psychological Review*, 65 (6): 386–408 (1958).
61. Ramesh, A. N., Kambhampati, C., Monson, J., and Drew, P. J., “Artificial intelligence in medicine”, *Ann R Coll Surg Engl*, 86: (2004).
62. Fujita, H., “AI-based computer-aided diagnosis (AI-CAD): the latest review to read first”, *Radiological Physics And Technology*, 13 (1): 6–19 (2020).
63. Hao, X., Zhang, G., and Ma, S., “Deep Learning”, *International Journal Of Semantic Computing*, 10 (3): 417–439 (2016).
64. Coşkun, F. and Güllerlioğlu, H. D., “Yapay Zekanın Tarih İçindeki Gelişimi ve Eğitimde Kullanılması”, *Ankara Üniversitesi Eğitim Bilimleri Fakültesi Dergisi*, 54 (3): 947–966 (2021).
65. Lecun, Y., Bottou, E., Bengio, Y., and Haffner, P., “Gradient-Based Learning Applied to Document Recognition”, *Proceedings Of The IEEE*, 86 (11): 2278–2324 (1998).
66. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., “GoogLeNet”, *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, (2014).



67. He, K., Zhang, X., Ren, S., and Sun, J., “ResNet”, *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, (2016).
68. Kaul, V., Enslin, S., and Gross, S. A., “History of artificial intelligence in medicine”, *Gastrointestinal Endoscopy*, 92 (4): 807–812 (2020).
69. Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., and Fei-Fei, L., “ImageNet Large Scale Visual Recognition Challenge”, *International Journal Of Computer Vision*, 115 (3): 211–252 (2015).
70. Albawi, S., Mohammed, T. A., and Al-Zawi, S., “Understanding of a convolutional neural network”, *Proceedings Of 2017 International Conference On Engineering And Technology, ICET 2017*, 2018-January: 1–6 (2018).
71. Li, Z., Liu, F., Yang, W., Peng, S., and Zhou, J., “A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects”, *IEEE Transactions On Neural Networks And Learning Systems*, 33 (12): 6999–7019 (2022).
72. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., and Chen, T., “Recent advances in convolutional neural networks”, *Pattern Recognition*, 77: 354–377 (2018).
73. O’Shea, K. and Nash, R., “An Introduction to Convolutional Neural Networks”, *International Journal For Research In Applied Science And Engineering Technology*, 10 (12): 943–947 (2015).
74. İnik, Ö. and Ülker, E., “Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri”, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3): 85–104 (2017).
75. Ajit, A., Acharya, K., and Samanta, A., “A Review of Convolutional Neural Networks”, *International Conference On Emerging Trends In Information Technology And Engineering, Ic-ETITE 2020*, (2020).
76. Lopez Pinaya, W. H., Vieira, S., Garcia-Dias, R., and Mechelli, A., “Convolutional neural networks”, *Machine Learning: Methods and Applications to Brain Disorders, Elsevier*, 173–191 (2019).
77. Teuwen, J. and Moriakov, N., “Convolutional neural networks”, *Handbook of Medical Image Computing and Computer Assisted Intervention, Elsevier*, 481–501 (2019).
78. Srivastava, N., Hinton, G., Krizhevsky, A., and Salakhutdinov, R., “Dropout: A Simple Way to Prevent Neural Networks from Overfitting”, *Journal Of Machine Learning Research*, 15: 1929–1958 (2014).

79. Chen, Y., Goorden, M. C., Beekman, F. J., and Du, J., “Understanding of Object Detection Based on CNN Family and YOLO”, *Journal Of Physics: Conference Series*, 1004 (1): 012029 (2018).
80. He, K., Zhang, X., Ren, S., and Sun, J., “Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition”, *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 37 (9): 1904–1916 (2015).
81. İnternet: Aditi M, “Instance Segmentation Using Mask R-CNN”, <https://aditi-mittal.medium.com/instance-segmentation-using-mask-r-cnn-7f77> (2023).
82. He, K., Gkioxari, G., Dollár, P., and Girshick, R., “Mask R-CNN”, *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 42 (2): 386–397 (2020).
83. Nur Omeroglu, A., Kumbasar, N., Argun Oral, E., and Ozbek, I. Y., “Hangar detection with mask R-CNN algorithm”, *27th Signal Processing And Communications Applications Conference, SIU 2019*, (2019).
84. Kokash, N., “An introduction to heuristic algorithms”, *Department Of Informatics And Telecommunications*, 1–8 (2005).
85. KOÇOĞLU, F. and EROL, Ç., “Algoritma”, *Tıp Bilişimi*, (2021).
86. Harorlu, A., Akgül, H. M., Yılmaz, A. B., Bilge, O. M., Dağistan, S., Çakur, B., Çağlayan, F., Miloğlu, Ö., and Sümbüllü, M. A., “Ağız, Diş ve Çene Radyolojisi”, *Nobel Tıp Kitabevleri*, 138–162 (2014).
87. Aps, J., “Radiography in pediatric dental practice”, *Clinical Dentistry Reviewed 2020 4:1*, 4 (1): 1–16 (2020).
88. Vandenberghe, B., Jacobs, R., and Bosmans, H., “Modern dental imaging: a review of the current technology and clinical applications in dental practice”, *European Radiology 2010 20:11*, 20 (11): 2637–2655 (2010).
89. Freeman, J. P. and Brand, J. W., “Radiation doses of commonly used dental radiographic surveys”, *Oral Surgery, Oral Medicine, Oral Pathology*, 77 (3): 285–289 (1994).
90. Van Aken, J. and Van der Linden, L. W. J., “The integral absorbed dose in conventional and panoramic complete-mouth examinations”, *Oral Surgery, Oral Medicine, Oral Pathology*, 22 (5): 603–616 (1966).
91. Patel, S., Durack, C., Abella, F., Shemesh, H., Roig, M., and Lemberg, K., “Cone beam computed tomography in Endodontics – a review”, *International Endodontic Journal*, 48 (1): 3–15 (2015).
92. Patel, S., “New dimensions in endodontic imaging: Part 2. Cone beam computed tomography”, *International Endodontic Journal*, 42 (6): 463–475 (2009).

93. Kröger, E., Dekiff, M., and Dirksen, D., “3D printed simulation models based on real patient situations for hands-on practice”, *European Journal Of Dental Education*, 21 (4): e119–e125 (2017).
94. Abdelkarim, A., Benghuzzi, H., Hamadain, E., Tucci, M., Ford, T., and Sullivan, D., “U.S. Dental Students’ and Faculty Members’ Attitudes About Technology, Instructional Strategies, Student Diversity, and School Duration: A Comparative Study”, *Journal Of Dental Education*, 78 (4): 614–621 (2014).
95. Manigandan, T., Sumathy, C., Elumalai, M., Sathasivasubramanian, S., and Kannan, A., “Forensic radiology in dentistry”, *Journal Of Pharmacy & Bioallied Sciences*, 7 (Suppl 1): S260 (2015).
96. Doi, K., “Computer-aided diagnosis in medical imaging: Historical review, current status and future potential”, *Computerized Medical Imaging And Graphics*, 31 (4–5): 198–211 (2007).
97. Schwendicke, F., Singh, T., Lee, J. H., Gaudin, R., Chaurasia, A., Wiegand, T., Uribe, S., and Krois, J., “Artificial intelligence in dental research: Checklist for authors, reviewers, readers”, *Journal Of Dentistry*, 107: 103610 (2021).
98. Willeminck, M. J., Koszek, W. A., Hardell, C., Wu, J., Fleischmann, D., Harvey, H., Folio, L. R., Summers, R. M., Rubin, D. L., and Lungren, M. P., “Preparing medical imaging data for machine learning”, *Radiology*, 295 (1): 4–15 (2020).
99. Anguita, D., Ghelardoni, L., Ghio, A., Oneto, L., and Ridella, S., “The “K” in K-fold Cross Validation”, *European Symposium On Artificial Neural Networks, Computational Intelligence And Machine Learning (ESANN)*, 441–446 (2012).
100. Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., and Zitnick, C. L., “Microsoft COCO: Common Objects in Context”, *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 8693 LNCS (PART 5): 740–755 (2014).

## ÖZGEÇMİŞ

Ahmet KARAOĞLU ilk ve orta öğrenimini Karabük'te, lise öğrenimini İstanbul'da tamamladı. 2005 yılında o zamanki adı ile Zonguldak Karaelmas Üniversitesi Karabük Meslek Yüksekokulu Bilgisayar Teknolojisi ve Programlama bölümünü bitirdi. 2009 yılında lisans eğitimini Karabük Üniversitesi Teknik Eğitim Fakültesi Bilgisayar Öğretmenliği programında, 2020 yılında, yine lisans eğitimini Karabük Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünde tamamladı. 2014 yılında Karabük Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar Eğitimi Anabilim Dalında yüksek lisans eğitimini tamamladı. Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Ana Bilim dalında 2018 yılında başladığı doktora eğitimine devam etmektedir. 2009 yılından beri Sinop Üniversitesi Gerze Meslek Yüksekokulu Bilgisayar Teknolojileri Bölümünde görev yapmaktadır.