

TÜRKİYE CUMHURİYETİ  
NECMETTİN ERBAKAN ÜNİVERSİTESİ  
DİŞ HEKİMLİĞİ FAKÜLTESİ

**BİTEWİNG RADYOGRAFİLERDE İNTERPROKSİMAL, OKLUZAL VE  
SEKONDER ÇÜRÜKLERİN YAPAY ZEKÂ İLE OTOMATİK TESPİTİ: KLİNİK  
KULLANIM İÇİN ARAYÜZ TASARIMI**

DT. RABİA KARAKUŞ  
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ UZMANLIK PROGRAMI  
DİŞ HEKİMLİĞİNDE UZMANLIK TEZİ

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANA BİLİM DALI  
TEZ DANIŞMANI  
DOÇ. DR. MELEK TAŞSÖKER

KONYA 2023

TÜRKİYE CUMHURİYETİ  
NECMETTİN ERBAKAN ÜNİVERSİTESİ  
DİŞ HEKİMLİĞİ FAKÜLTESİ

**BİTEWİNG RADYOGRAFİLERDE İNTERPROKSİMAL, OKLUZAL VE  
SEKONDER ÇÜRÜKLERİN YAPAY ZEKÂ İLE OTOMATİK TESPİTİ:  
KLİNİK KULLANIM İÇİN ARAYÜZ TASARIMI**

DT. RABİA KARAKUŞ  
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ UZMANLIK PROGRAMI  
DİŞ HEKİMLİĞİNDE UZMANLIK TEZİ

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANA BİLİM DALI  
TEZ DANIŞMANI  
DOÇ. DR. MELEK TAŞSÖKER

KONYA 2023

## TEZ ONAY SAYFASI

Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı Uzmanlık Öğrencisi RABİA KARAKUŞ'un "Bitewing Radyografilerde İnterproksimal, Okluzal ve Sekonder Çürüklerin Yapay Zeka ile Otomatik Tespiti: Klinik Kullanım İçin Arayüz Tasarımı" başlıklı tezi tarafımızdan incelenmiş; amaç, kapsam ve kalite yönünden Diş Hekimliğinde Uzmanlık Tezi olarak kabul edilmiştir.

Konya / . . 2022

|               |                                                                                                                                          |      |
|---------------|------------------------------------------------------------------------------------------------------------------------------------------|------|
| Tez Danışmanı | Doç. Dr. Melek TAŞSÖKER<br>Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi<br>Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı        | İmza |
| Jüri Üyesi    | Doç. Dr. Melek TAŞSÖKER<br>Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi<br>Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı        | İmza |
| Jüri Üyesi    | Dr. Öğr. Üyesi İlknur Eninanç<br>Sivas Cumhuriyet Üniversitesi Diş Hekimliği Fakültesi<br>Ağız, Diş ve Çene Radyolojisi Anabilim Dalı    | İmza |
| Jüri Üyesi    | Dr. Öğr. Üyesi Melike Güleç<br>Karamanoğlu Mehmetbey Üniversitesi Diş Hekimliği Fakültesi<br>Ağız, Diş ve Çene Radyolojisi Anabilim Dalı | İmza |

Yukarıdaki tez, Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Yönetim Kurulunun .../.../2023 tarih ve ..... sayılı kararı ile onaylanmıştır.

Prof. Dr. Ali Rıza TUNÇDEMİR  
Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Dekanı  
İmzası

## APPROVAL

We certify that we have read this dissertation entitled “Automatic Detection of Interproximal, Occlusal, and Secondary Caries on Bite-wing Radiography with Artificial Intelligence” by “RABİA KARAKUŞ” that in our opinion it is fully adequate, in scope and quality, as dissertation for the degree of Master of Science in the Department of Oral and Maxillofacial Radiology, Faculty of Dentistry University of Necmettin Erbakan

Konya, Turkey / . . 2023

|                   |                                                   |           |
|-------------------|---------------------------------------------------|-----------|
| Principal Advisor | Associate Professor Melek TAŞSÖKER                | Signature |
|                   | Necmettin Erbakan University Faculty of Dentistry |           |
|                   | Department of Oral and Maxillofacial Radiology    |           |

|                       |                                                          |           |
|-----------------------|----------------------------------------------------------|-----------|
| Examination Committee | Associate Professor Melek TAŞSÖKER                       | Signature |
|                       | Member Necmettin Erbakan University Faculty of Dentistry |           |
|                       | Department of Oral and Maxillofacial Radiology           |           |

|                       |                                                         |           |
|-----------------------|---------------------------------------------------------|-----------|
| Examination Committee | Assistant Professor İlknur Eninanc                      | Signature |
|                       | Member Sivas Cumhuriyet University Faculty of Dentistry |           |
|                       | Department of Oral and Maxillofacial Radiology          |           |

|                       |                                                              |           |
|-----------------------|--------------------------------------------------------------|-----------|
| Examination Committee | Assistant Professor Melike Güleç                             | Signature |
|                       | Member Karamanoğlu Mehmetbey University Faculty of Dentistry |           |
|                       | Department of Oral and Maxillofacial Radiology               |           |

This thesis has approved for the University of Necmettin Erbakan Faculty of Dentistry.

Dean

Prof. Dr. Ali Rıza TUNÇDEMİR

Necmettin Erbakan University Faculty of Dentistry

/ 2023

## BEYANAT

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

22/12/2023

Dt. Rabia KARAKUŞ

İmzası

## ORJİNALLİK RAPORU

### BİTEWİNG RADYOGRAFİLERDE İNTERPROKSİMAL, OKLUZAL VE SEKONDER ÇÜRÜKLERİN YAPAY ZEKÂ İLE OTOMATİK TESPİTİ: KLİNİK KULLANIM İÇİN ARAYÜZ TASARIMI

#### ORJİNALLİK RAPORU

|                   |                     |            |                  |
|-------------------|---------------------|------------|------------------|
| % <b>13</b>       | % <b>12</b>         | % <b>3</b> | % <b>5</b>       |
| BENZERLİK ENDEKSİ | İNTERNET KAYNAKLARI | YAYINLAR   | ÖĞRENCİ ÖDEVLERİ |

#### BİRİNCİL KAYNAKLAR

|          |                                                                                                              |             |
|----------|--------------------------------------------------------------------------------------------------------------|-------------|
| <b>1</b> | <b>acikbilim.yok.gov.tr</b><br>İnternet Kaynağı                                                              | % <b>4</b>  |
| <b>2</b> | <b>acikerisim.dicle.edu.tr:8080</b><br>İnternet Kaynağı                                                      | % <b>1</b>  |
| <b>3</b> | <b>www.gecekitapligi.com</b><br>İnternet Kaynağı                                                             | % <b>1</b>  |
| <b>4</b> | <b>www.iot.gen.tr</b><br>İnternet Kaynağı                                                                    | % <b>1</b>  |
| <b>5</b> | <b>acikerisim.karabuk.edu.tr:8080</b><br>İnternet Kaynağı                                                    | <% <b>1</b> |
| <b>6</b> | <b>dergipark.org.tr</b><br>İnternet Kaynağı                                                                  | <% <b>1</b> |
| <b>7</b> | <b>jag.journalagent.com</b><br>İnternet Kaynağı                                                              | <% <b>1</b> |
| <b>8</b> | <b>Submitted to The Scientific &amp; Technological Research Council of Turkey (TUBITAK)</b><br>Öğrenci Ödevi | <% <b>1</b> |

## TEŞEKKÜR

Uzmanlık eğitimim boyunca bilgi ve tecrübelerinden çok şey öğrendiğim, tez çalışmamda her daim bana yol gösteren tez danışmanım değerli hocam **Doç. Dr. Melek Taşşöker**'e ve yine tezimde emeği büyük olan aynı zamanda yapay zekâ ile ilgili her aşamada bana yardımcı olan **Dr. Öğr. Üyesi M. Üsame Öziç**'e her şey için en içten duygularıyla teşekkür ederim.

Ve hayatım boyunca desteklerini ve varlıklarını hep hissettiğim bugünlere gelmemi sağlayan başta canım annem **Sultan Karakuş** olmak üzere biricik aileme ve uzmanlık eğitimim boyunca iyi ve kötü günümde her zaman yanımda olan sevgili arkadaşlarım **Uzm. Dt. Mehmet Akyüz, Arş. Gör. Dt. Cemile Nur Yıldırım, Arş. Gör. Dt. Mediha Ertürk, Arş. Gör. Dt. Taha Zirek** ve **Arş. Gör. Dt. Sultan Uzun**'a destekleri için çok teşekkür ederim.

Üzerimde emeği olan ve desteklerini esirgemeyen Ağız Diş ve Çene Radyolojisi Anabilim Dalı'nda görevli hocalarıma teşekkür ederim.

Uzmanlık eğitimim boyunca birçok anı paylaştığım her birini kardeşim gibi sevdiğim Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi öğrencilerine teşekkür ederim.

## İÇİNDEKİLER

|                                                  |      |
|--------------------------------------------------|------|
| <i>İç Kapak</i> .....                            | ii   |
| <i>Tez Onay Sayfası</i> .....                    | iii  |
| <i>Approval</i> .....                            | iv   |
| <i>Beyanat</i> .....                             | v    |
| <i>Orijinallik Raporu</i> .....                  | vi   |
| <i>Teşekkür</i> .....                            | vii  |
| <i>İçindekiler</i> .....                         | viii |
| <i>Kısaltmalar Ve Simgeler</i> .....             | x    |
| <i>Şekiller Listesi</i> .....                    | xii  |
| <i>Resimler Listesi</i> .....                    | xiii |
| <i>Tablolar Listesi</i> .....                    | xiv  |
| <i>Özet</i> .....                                | xv   |
| <i>Abstract</i> .....                            | xvi  |
| <b>1. GİRİŞ</b> .....                            | 1    |
| <b>2. GENEL BİLGİLER</b> .....                   | 4    |
| 2.1. <i>Diş Çürüğü</i> .....                     | 4    |
| 2.2 <i>Diş Çürüğünün Sınıflandırılması</i> ..... | 4    |
| 2.2.1. <i>Mine Çürüğü</i> .....                  | 5    |
| 2.2.2. <i>Dentin Çürüğü</i> .....                | 8    |
| 2.2.3. <i>Pit Ve Fissür Çürükleri</i> .....      | 11   |
| 2.2.4. <i>İnterproksimal Çürükler</i> .....      | 12   |
| 2.2.5. <i>Sekonder Çürük</i> .....               | 13   |
| 2.3. <i>Çürük Teşhis Yöntemleri</i> .....        | 13   |
| 2.3.1. <i>Görsel Muayene</i> .....               | 14   |
| 2.3.2. <i>Ayna-Sond İle Muayene</i> .....        | 15   |
| 2.3.3. <i>Radyografik Muayene</i> .....          | 15   |

|           |                                                                           |    |
|-----------|---------------------------------------------------------------------------|----|
| 2.4.      | <i>Yapay Zekâ</i> .....                                                   | 17 |
| 2.4.1.    | <i>Yapay Zekânın Kronolojik Gelişimi</i> .....                            | 19 |
| 2.4.2.    | <i>Yapay Zekânın Avantajları Ve Dezavantajları</i> .....                  | 21 |
| 2.4.3.    | <i>Yapay Zekâ Teknikleri</i> .....                                        | 23 |
| 2.4.4.    | <i>Makine Öğrenimi</i> .....                                              | 35 |
| 2.4.5.    | <i>Derin Öğrenme</i> .....                                                | 36 |
| <b>3.</b> | <b>GEREÇ VE YÖNTEM</b> .....                                              | 51 |
| 3.1.      | <i>Gereç</i> .....                                                        | 51 |
| 3.1.1.    | <i>Görüntülerin Toplanması</i> .....                                      | 51 |
| 3.2.      | <i>Yöntem</i> .....                                                       | 52 |
| 3.2.1.    | <i>Görüntü Ön İşleme</i> .....                                            | 52 |
| 3.2.2.    | <i>Görüntülere Sınırlayıcı Kutuların Çizilmesi Ve Etiketlenmesi</i> ..... | 54 |
| 3.2.3.    | <i>Veri Setlerinin Oluşturulması</i> .....                                | 57 |
| 3.2.4.    | <i>Yolo V8 İle Model Eğitimi</i> .....                                    | 57 |
| 3.2.5.    | <i>Performans Kriterleri</i> .....                                        | 58 |
| 3.2.6.    | <i>Klinik İçin Grafıksel Kullanıcı Arayüz Tasarımı</i> .....              | 61 |
| <b>4.</b> | <b>BULGULAR</b> .....                                                     | 62 |
| 4.1.      | <i>Eğitim Sonuçları</i> .....                                             | 62 |
| 4.2.      | <i>Test Sonuçları</i> .....                                               | 63 |
| <b>5.</b> | <b>TARTIŞMA</b> .....                                                     | 68 |
| <b>6.</b> | <b>SONUÇLAR VE ÖNERİLER</b> .....                                         | 81 |
| <b>7.</b> | <b>KAYNAKLAR</b> .....                                                    | 82 |
| <b>8.</b> | <b>ÖZGEÇMİŞ</b> .....                                                     | 94 |
| <b>9.</b> | <b>EKLER</b> .....                                                        | 94 |

## KISALTMALAR VE SİMGELER

|      |                                       |
|------|---------------------------------------|
| AP   | Average Precision                     |
| CNN  | Convolutional Neural Network          |
| COCO | Common in Context                     |
| DN   | Doğru Negatif                         |
| DP   | Doğru Pozitif                         |
| DPM  | Deformable Part Model                 |
| EEG  | Elektroensefalografi                  |
| EKG  | Elektrokardiyografi                   |
| EMG  | Elektromiyografi                      |
| FOTI | Fiber Optik Transillüminasyon         |
| IoU  | Intersection Union                    |
| KSA  | Konvolüsyonel Sinir Ağı               |
| kVP  | Pik Kilovaltoj                        |
| LVQ  | Learning Vector Quantization          |
| mA   | Miliamper                             |
| mAP  | Mean Average Precision                |
| MLP  | Multilayered Perceptrons              |
| MRG  | Manyetik Rezonans Görüntüleme         |
| ms   | Milisaniye                            |
| HOG  | Histogram of Oriented Gradients       |
| LBP  | Local Binary Pattern                  |
| MKL  | Multiple Kernel Learning              |
| QLF  | Quantitative Luminescent Fluorescence |
| RBM  | Restricted Boltzman Machine           |
| RCNN | Region Based Convolutional Networks   |

|        |                               |
|--------|-------------------------------|
| RNN    | Recurrent Neural Network      |
| SSD    | Single-Shot Detector          |
| YP     | Yanlış Pozitif                |
| YN     | Yanlış Negatif                |
| YOLO   | You Look Only Once            |
| YOLOv2 | You Look Only Once versiyon 2 |
| YOLOv3 | You Look Only Once versiyon 3 |
| YOLOv4 | You Look Only Once versiyon 4 |
| YOLOv5 | You Look Only Once versiyon 5 |
| YOLOv6 | You Look Only Once versiyon 6 |
| YOLOv7 | You Look Only Once versiyon 7 |
| YOLOv8 | You Look Only Once versiyon 8 |
| YP     | Yanlış Pozitif                |
| YSA    | Yapay Sinir Ağı               |
| µm     | Mikrometre                    |

## ŞEKİLLER LİSTESİ

**Şekil 1:** Uzman sistemlerin şematize edilmesi

**Şekil 2:** Bulanık mantığın şematize edilmesi

**Şekil 3:** Yapay sinir ağları

**Şekil 4:** Biyolojik sinir hücresi ve yapay sinir ağı

**Şekil 5:** Çok katmanlı algılayıcıların yapısı

**Şekil 6:** Derin öğrenme metodunun diğer yapay zeka teknikleriyle olan ilişkisi

**Şekil 7:** Epoch ilerleyişine göre performans kriterlerinin grafiksel gösterimi

**Şekil 8:** Sınıflara göre precision-recall grafiği ve performans sonuçları

## RESİMLER LİSTESİ

**Resim 1:** Mine çürüğü tabakaları

**Resim 2:** Dentin çürüğünün sınıflandırılması

**Resim 3:** Derin öğrenme ile nesne tespiti

**Resim 4:** YOLO nesne tespiti akış şeması

**Resim 5:** Bitewing augmentasyon yöntemleriyle çoğaltılması

**Resim 6:** makesense.ai sitesinin ana sayfa ekran görüntüsü

**Resim 7:** makesense.ai sitesinde etiketlemenin yapıldığı ekran (Sekonder çürük, okluzal çürük, d3 ve d2 interproksimal çürüklerinin etiketlendiği bir bitewing radyograf)

**Resim 8:** makesense.ai sitesinde etiketlemenin yapıldığı ekran (d1 ve d2 interproksimal çürüklerinin etiketlendiği bir bitewing radyograf)

**Resim 9:** YOLOv8 bitewing radyograflarda çürük tespiti arayüz tasarımı

**Resim 10:** 8 adet test görüntüsü üzerinde çürüklerin otomatik tespiti ve sınıf bilgileri

## TABLÖLAR LİSTESİ

**Tablo 1:** İnterproksimal çürük sınıflandırılması

**Tablo 2:** Çürük teşhis yöntemlerinin sınıflandırılması

**Tablo 3:** Biyolojik sinir sistemi elemanları ve yapay sinir sistemindeki karşılıkları

**Tablo 4:** Eğitim ve validasyon sonucu elde edilen performans sonuçları

**Tablo 5:** Karmaşıklık matriksi

**Tablo 6:** Test verileri, DP, YP, YN sayıları ve performans kriterleri



## ÖZET

T.C. NECMETTİN ERBAKAN ÜNİVERSİTESİ  
DİŞ HEKİMLİĞİ FAKÜLTESİ

### **BİTEWİNG RADYOGRAFİLERDE İNTERPROKSİMAL, OKLUZAL VE SEKONDER ÇÜRÜKLERİN YAPAY ZEKÂ İLE OTOMATİK TESPİTİ: KLİNİK KULLANIM İÇİN ARAYÜZ TASARIMI**

DT. RABİA KARAKUŞ

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ UZMANLIK PROGRAMI  
DİŞ HEKİMLİĞİNDE UZMANLIK TEZİ/KONYA-2023

Dış çürüklerinin erken tespiti, invaziv tedaviyi önleyebilir ve böylece sağlık bakım maliyetlerinden tasarruf sağlayabilir; ancak interproksimal çürüklerin yalnızca klinik muayene ile tespit edilmesi zordur ve bitewing radyografisi demineralize interproksimal çürüklerin teşhisinde altın standarttır. YOLO algoritması, evrişimli sinir ağı (CNN) tabanlı bir derin öğrenme modelidir ve YOLOv8, nesne algılama, görüntü sınıflandırma ve örnek segmentasyon görevleri için kullanılabilecek en yeni YOLO modelidir.

Bu çalışmada, bitewing radyograflarda sekonder, okluzal ve interproksimal (d1-d2-d3) çürüklerin tespitinde YOLOv8 algoritmasının başarısının belirlenmesi amaçlandı.

Bu çalışmada fakülte veri tabanından 860 adet bitewing radyograf toplandı. Augmentasyon yöntemleriyle bitewing görüntü sayısı 3440'a çıkarıldı. Oral radyologlar, bitewing radyograflardaki çürük lezyonlarını d1, d2, d3, sekonder ve okluzal olarak etiketlediler. Veriler rastgele olarak %80 eğitim, %10 doğrulama ve %10 test olarak bölündü. Dış çürüklerine ilişkin ağırlık dosyası, YOLOv8 algoritmasının transfer öğrenme yöntemiyle eğitilmesiyle elde edildi. Elde edilen ağırlıklar kullanılarak test radyograflarında algoritmanın daha önce görmediği dış çürükleri otomatik olarak tespit edildi. Test sonuçları iki oral radyolog tarafından değerlendirildi ve performans kriterleri hesaplandı.

Test görüntülerinde sekonder, okluzal ve interproksimal çürükler için ortalama kesinlik, ortalama duyarlılık ve ortalama F1 skoru değerleri sırasıyla 0,977, 0,932 ve 0,954 olarak elde edildi.

Bitewing radyograflarla eğitilen YOLOv8 algoritması, yüksek başarı oranlarıyla farklı dış çürüğü lezyonlarını tespit etti.

**Anahtar Kelimeler:** Derin öğrenme, Dış çürüğü, YOLO, Bitewing

## **ABSTRACT**

T.C.

NECMETTIN ERBAKAN UNIVERSITY

FACULTY OF DENTISTRY

### **AUTOMATIC DETECTION OF INTERPROXIMAL, OCCLUSAL AND SECONDARY CARIIES IN BITEWING RADIOGRAPHIES WITH ARTIFICIAL INTELLIGENCE: INTERFACE DESIGN FOR CLINICAL USE**

DT. RABIA KARAKUS

MASTER OF SCIENCE IN THE DEPARTMENT OF

ORAL AND MAXILLOFACIAL RADIOLOGY/KONYA-2023

Early detection of dental caries can prevent invasive treatment and thus save healthcare costs; however, interproximal caries are difficult to detect by clinical examination alone, and bitewing radiography is the gold standard for diagnosing demineralized interproximal caries. YOLO algorithm is a convolutional neural network (CNN) based deep learning model, and YOLOv8 is the latest YOLO model that can be used for object detection, image classification, and instance segmentation tasks.

This study aimed to determine the success of the YOLOv8 algorithm in detecting secondary, occlusal and interproximal (d1-d2-d3) caries on bitewing radiographs.

In this study, 860 bitewing radiographs were collected from the faculty database. The number of bitewing images was increased to 3440 with augmentation methods. Oral radiologists labeled caries lesions on bitewing radiographs as d1, d2, d3, secondary, and occlusal. The data was randomly split into 80% training, 10% validation, and 10% testing. The weight file for dental caries was obtained by training the YOLOv8 algorithm with the transfer learning method. Using the obtained weights, tooth decay that the algorithm had not seen before was automatically detected in the test radiographs. Test results were evaluated by two oral radiologists and performance criteria were calculated.

In the test images, the average precision, average sensitivity and average F1 score values for secondary, occlusal and interproximal caries were obtained as 0.977, 0.932 and 0.954, respectively.

Trained on bitewing radiographs, the YOLOv8 algorithm detected different types of dental caries lesions with high success rates.

**Keywords:** Deep learning, Tooth decay, YOLO, Bitewing

## 1. GİRİŞ

Diş çürükleri, günümüzde insanların çok yaygın kronik hastalıklarından biridir ve insanlığın yaşamları süresince bu hastalığa yakalanma riski vardır (Pitts 2004). Diş çürükleri çoğunlukla yavaş ilerlemesine rağmen tedaviye geç başlanırsa ağrıya, enfeksiyona ve diş kayıplarına sebebiyet verebilmektedir (Mortensen ve ark. 2016).

Diş hekimliği pratiğinde geçmişten günümüze kadar kabul gören bazı yaklaşımlar lezyonları kavitasyon aşamasında tespit etmeye odaklanmıştır (Fejerskov ve ark. 2015). Geleneksel yaklaşımların restoratif diş tedavisine bakış açısı, çürüğün geleneksel kavite açıp ortadan kaldırılması ve bölgenin restore edilmesi yönündeydi, ancak günümüzde modern diş hekimliğinde bu görüş değişmiştir. Koruyucu ve olabildiğince non invaziv tedaviler uygulanmaya başlanmıştır (Pitts 2004). Bundan dolayı, çürüklerin tedavisini belirlemede erken ve doğru teşhis çok önemlidir. Başarılı bir tedavi doğru zamanda yapılan doğru teşhisten geçmektedir (Baelum ve ark. 2006).

Diş çürüklerinin tedavisi için geliştirilen çeşitli restorasyon yöntemleri ilerleyen yıllarda başarılı bir şekilde geliştirilmiştir (Tyas ve ark. 2000; Featherstone 2004). Bununla birlikte, dişlerin çeşitli anatomik morfolojileri ve varyasyonları nedeniyle diş çürüklerinin belirlenmesi için tanı metodolojisinde henüz önemli bir gelişme kaydedilememiştir. Özellikle derin fissürler, sıkı interproksimal kontaklar ve sekonder lezyonlar varlığında erken teşhis zordur ve çürük çoğunlukla ileri evrelerde tespit edilir. Çürük teşhisinde yaygın olarak dental radyografiler (panoramik, periapikal ve bitewing) ve dental sondlar kullanılmaktadır (Lee ve ark. 2018).

Çürüklerin tespiti, lezyonların önlenmesi ve tedavisinde kilit bir unsurdur ve diş hekimliğinde zor bir iştir. Geleneksel yöntemler çürük teşhisi için zor ve kısıtlı olduğu için yeni yöntemler ve cihazlar geliştirilmiştir. Bu yöntemlerdeki eksikliklerin sonucu olarak çürük teşhisi ve lokalizasyon belirleme için yapay zekâ yöntemleri diş hekimliğinde kullanılmaya başlanmıştır (Rodrigues ve ark. 2008)

Yapay zekâ (Artificial Intelligence), akıllı davranış olarak bilinen ve isimlendirilen tanımın sayısal olarak açıklanmasıyla ve bu davranışları gösteren eserlerin icat edilmesiyle ilgilenen bir bilim ve mühendislik alanıdır (Shapiro 1992). Günlük yaşantımızda mühendislik, elektronik, endüstri alanları gibi birçok alanda hayatımızı kolaylaştırmaya devam etmektedir (Parunak 1996; Malik ve ark. 2018). Hemen hemen her alanda kendini gösteren yapay zekâ tıp alanında da birçok yeniliğe ve gelişime imza atmıştır ve gelişmeye de devam etmektedir (Davenport ve Kalakota 2019).

Tıpta zaman kazanımı, malpraktisleri azaltmayı, insan iş gücünü minimumda tutmayı amaçlamaktadır (Hung ve ark. 2020). Yapay zekânın bilgisayarla görme olarak bilinen görsel görevlere uygulanması, tıp camiasında önemli bir ilgi yarattı. Bu nedenle, yapay zekânın radyoloji, patoloji, oftalmoloji ve dermatoloji gibi görsel ağırlıklı uzmanlıklarda kullanımı ilgili olduğuna inanılmaktadır. Yapay zekânın gelişiminin arkasındaki güç, büyük dijital veri kümelerinin kullanılabilirliğidir; derin öğrenme algoritmaları, bir görüntüdeki lezyonu tanımlamak gibi belirli bir görevi gerçekleştirmek üzere kendilerini eğitmek için bu dijital veri kümelerini kullanır (Davenport ve Kalakota 2019).

Yapay zekâ diş hekimliğinde de kendine uygulama alanları bulmuştur. Diş hekimliğinde yapay zekâ uygulamaları çoğunlukla sanaldır ve lezyonlar ile normal dokular arasında ayırım yapmak, risk faktörlerine öncelik vermek ve ileriye dönük sonuçları simüle etmek ve değerlendirmek için yapay zekâ algoritmaları kullanır (Shan ve ark. 2021). Diş hekimliğinde kök kanal sistemi anatomisini incelemek, periapikal lezyonları ve kök kırıklarını tespit etmek, çalışma uzunluğu ölçümlerini belirlemek, dental pulpanın canlılığını tahmin etmek gibi çeşitli uygulamalarda kendini göstermiştir (Aminoshariae ve ark. 2021).

Radyoloji alanında yapay zekâ üzerine yapılan son araştırmalarda, esas olarak görüntü sınıflandırma, algılama, segmentasyon, kayıt, üretim ve iyileştirme yapabilen evrişimli sinir ağları kullanılmıştır. Bu alandaki yapay zekâ sistemleri, radyografik

teşhis, görüntü analizi, adli diş hekimliği ve görüntü kalitesinin iyileştirilmesi amacıyla geliştirilmiştir. İyi sonuçlar elde etmek için fazla miktarda veriye ihtiyaç vardır ve radyoloğun katılımı, zaman alıcı bir görevdir ancak doğru ve tutarlı veri setleri oluşturmak için esastır (Heo ve ark. 2021).

Günümüze kadar yapılan yapay zekâ çalışmaları içerisinde bitewing radyograflar üzerinde çürük tespiti vardır (Kühnisch ve ark. 2022); ancak daha önce aynı çalışmada hem okluzal, hem interproksimal (d1-d2-d3), hem de sekonder çürükleri sınıflandırıp tespitini yapan yapay zekâ çalışması bulunmamıştır. Bu tez çalışmasında YOLOv8 algoritmasını kullanarak bitewing radyograflarda interproksimal, okluzal ve sekonder çürükler tespit edilmeye çalışılmıştır.

## **2.GENEL BİLGİLER**

### **2.1. DİŞ ÇÜRÜĞÜ**

Diş çürüğü çağımızın çok sık rastlanan kronik hastalıklarından biridir. Çürük, bakteriler ve duyarlı konakçı faktörler tarafından diyet karbonhidratlarının fermentasyonundan üretilen asitler arasındaki sinerjik kompleks etkilerle diş dokularının tahrip edilmesidir. (Selwitz ve ark. 2007). Genellikle sakkaroz gibi basit karbonhidratların oral mikroorganizmalar tarafından fermentasyonundan kaynaklanır. Streptokoklar ve laktobasiller bu oral mikroorganizmaların başında gelir (Batra ve ark. 2020).

Multifaktöriyel bir hastalık olan diş çürüğünün etiyolojisinde, dental plak, konak, diyet ve zaman benzeri ana bileşenler vardır (Ritter 2017). Diş çürükleri dişin dış yüzeyinde başlayan ve dentin yoluyla pulpaya ilerleyebilen ve dişin vitalitesini etkileyebilen bir mineral kaybıyla sonuçlanır. Çürüğün ilerlemesini durdurmak için erken teşhis koyulması ve risk faktörlerinin belirlenmesi önemlidir. Risk faktörleri arasında çürük, eksik ve dolgulu yüzey/diş sayısı; fermente edilebilir karbonhidratların (şekerler) alım sıklığı; florür mevcudiyeti; plak temizleme etkinliği ve sıklığı; tükürük özellikleri ve akışı; diş morfolojisi vardır (Guzmán-Armstrong 2005).

### **2.2 DİŞ ÇÜRÜĞÜNÜN SINIFLANDIRILMASI**

Diş çürükleri tanımlanmak ve tedavisi yapılmak üzere birçok farklı sınıflandırmalara tabii tutulmuştur. Çürüğün bulunduğu sert dokuya, diş üzerindeki konumuna ilişkin yapılan sınıflamalar en fazla kullanılan sınıflamalardır (Mjör ve Toffenti 2000).

### Diş Üzerindeki Lokalizasyonuna Göre Çürükler;

- Tüberkül çürükleri,
- Kole çürükleri,
- Pit ve fissür çürükleri
- İnterproksimal bölge çürükleri olarak sınıflandırılmaktadır.

### Sert Doku Çürükleri;

- Mine çürüğü,
- Dentin çürüğü
- Sement çürüğü olarak sınıflandırılmaktadır.

### Tedavi Sonrası Oluşan Çürükler;

- Rezidüel çürükler
- Sekonder çürükler şeklinde sınıflandırılmaktadır.

## **2.2.1. MİNE ÇÜRÜĞÜ**

Dişlerin dış yüzeyini kaplayan nano yapıli dokuya mine denir (Chatzistavrou ve ark. 2012). Dişin anatomik kronunun dış koruyucu kaplamasını oluşturan kalsifiye bir dokudur (Lacruz ve ark. 2017). Mine dokusu bir kez oluştuktan sonra biyolojik olarak tamir edilemez ve değıştirilemez (Angelova Volponi ve ark. 2018).

Mine dokusu oral flora ve tükürükle etkileşim içerisinde ve periodontal sağlıklı bireylerde çürük başlangıcı mine dokusunda başlar. Asidik bir etkileşimden sonra dişten mineral kaybetmeye demineralizasyon, bu minerallerin diş yapısına geri kazandırılmasına ise remineralizasyon denir (AlShehab ve ark. 2018).

Demineralizasyon sırasında, mine ile asitlerin teması sonucu mine yüzeyi pürüzlü ve geçirgen hale gelir. Minenin mineral dengesinin ve doku bütünlüğünün veya bozulmasının derecesini belirleyen mine demineralizasyon/remineralizasyon döngüleri vardır (Abou Neel ve ark. 2016).

Mine dekalsifikasyonu veya beyaz nokta lezyonları, pürüzsüz diş yüzeyinde kavitasyon olmaksızın süt beyazı opasiteler olarak ortaya çıkan, çürük demineralizasyondan kaynaklanan yüzey altı mine gözenekliliğidir (Sonesson ve ark. 2017). Mine dokusunun fiziksel özellikleri beyaz nokta lezyonlarının başlamasına elverişlidir; pürüzlü ve geçirgen yapısı küçük partiküllerin geçişine izin verir (Nanci 2008). Beyaz nokta lezyonları eğer remineralizasyon siklusu baskın olursa sağlıklı hale gelir ancak demineralizasyon siklusu baskın hale gelirse minede kavitasyon oluşmaya başlar (Robinson ve ark. 2000).

Beyaz nokta lezyonunun şekli, biyofilmin dağılımı ve mine prizmalarının yönü ile belirlenir. Biyofilmin altında oluşan lezyon, temas yüzeyi ile dişeti kenarı arasında böbrek şeklinde bir alandır. Minede, mine prizmaları boyunca çözünmenin yayılması gerçekleşir. Düz yüzeyli lezyon sagittal kesitte koniktir. Bu konik şekil, mine prizmaları boyunca çözünmedeki sistematik varyasyonların sonucudur (Kidd ve Fejerskov 2004).

Mine çürükleri tabakalardan oluşmaktadır. Tabakaların ayrımı diş morfolojisindeki mineral kaybı ve buna bağlı diş yapısındaki bozulmaların sınıflandırılmasıyla yapılır. Bu tabakalardan her biri çürükte görülmeyebilir ve genellikle 4 tabakadan oluşmaktadır (Yıkılğan ve Kılıç 2016).

#### **2.2.1.1. YÜZEYEL TABAKA**

- Çürüğün en dış tabakasıdır.
- Çürükte kavitasyon oluşana kadar bu tabakaya rastlanılabilir.

- Yapısının hipermineralize olması bu tabakanın altında ve ağız ortamındaki iyonların çökmesi kaynaklıdır.
- Kaviteasyon yoksa bu çürük katmanının korunması gereklidir (Holmgren ve ark. 2013).
- Bu tabaka mekanik olarak uzaklaştırılırsa remineralizasyon olasılığı kalmaz sonuç olarak invaziv tedaviler kaçınılmaz olur.
- Yüzeyel tabakanın sağlıklı dokuya göre geçirgenliği artmıştır. Bu sebepten iyon difüzyonu artmıştır.
- Yüzeyel tabakanın yapısı geçirgen olmasına rağmen bakterilerin derin dokulara penetre olmasına engel olur. (Holmgren ve ark. 2013).
- Radyolojik görüntüsü sağlam diş dokularından ayırt edilemeyebilir (Yıkılğan ve Kılıç 2016).

#### **2.2.1.2. LEZYONUN GÖVDESİ**

- Lezyon gövdesi yüzeyel tabakanın altında yer alır.
- Mine çürüğünün en geniş tabakasıdır.
- Retzius çizgileri belirginleşmiştir.
- Yüzeyel tabakanın geçirgenliğinin arttığı zaman ya da deformasyon bulunduğu zaman lezyonun gövdesinde mikroorganizma bulunabilir.
- Işık mikroskobu ile gözlemlendiğinde sağlıklı dokuya nazaran daha saydam bir görüntü vardır.
- Radyolojik görüntüsü ise radyolüsenttir (Hicks ve ark. 2004).


#### **2.2.1.3.KARANLIK TABAKA**

- Lezyonun gövdesinden sonra yer alan tabakadır.
- Karanlık tabaka adını kahverengi renkli olmasından alır.
- Daimi dişlerde rastlanan çürüklerin %85- 90'ında bulunur.
- Lezyonun gövdesindeki porlar bu tabakada remineralizasyonla mikroporlara dönüşmektedir.

- Hızlı ilerleyen çürüklerde inceyken yavaş ilerleyen çürüklerde ise kalın olarak gözlenmektedir (LeGeros 1991).

#### 2.2.1.4.SAYDAM TABAKA

- Çürüğün en son tabakasıdır.
- Sağlıklı mine dokusundan farkı yapısal özellikler gösteren ilk tabakadır.
- Mine çürüklerinin %50 'sinde bulunmaktadır.
- Sağlıklı mine dokusuna oranla çok daha geçirgendir.
- Mine çürüğünün ilerlediğinin kanıtıdır.
- Bu tabakada hem organik yapı hem inorganik yapının (retzius çizgileri, interprizmatik madde) deformasyonuna rastlanmaktadır (Featherstone 2008).



**Resim 1:** Mine çürüğünün tabakaları (Tetschke ve ark. 2020)

#### 2.2.2. DENTİN ÇÜRÜĞÜ

Bakteriyel asitler sadece dentin yüzeylerindeki organik matriksin demineralizasyonuna ve açığa çıkmasına neden olmakla kalmaz, aynı zamanda dentindeki ve tükürükteki matriks metalloproteinazları ve katepsinlerin aktivasyonunu da indükler. Bu fenomenler, dentin yüzeylerinde demineralize organik matriksin çözünmesini başlatır. Organik matriksin ilk çözünmesinde bakteri katılımı hiçbir

zaman doğrulanmamış olsa da dentin ve kök çürüklerinde proteolitik bakterilerin ve bakteriyel metabolitlerin tespiti, kısmen bozulmuş matriksin bir bakteriyel sindirimi ve metabolizmasını düşündürür (Takahashi ve Nyvad 2016).

Dentin çürükleri yumuşak dentin(enfekte dentin, bulanık dentin), transparan dentin, subtransparan dentin olmak üzere 4 bölgeye ayrılır (Arnold ve ark. 2003; Hickel ve ark. 2010).

#### **2.2.2.1. ENFEKTE DENTİN (YUMUŞAK DENTİN)**

- Dişin dış tabakasında bulunan klinik olarak yumuşak dentin, mikrobiyal biyofilmin bağlı olduğu nekrotik bölge ve kontamine bölgeden oluşur (Schwendicke ve ark. 2016)
- Bu tabaka tamamen kaldırılmalıdır aksi takdirde çürük lezyonu kontrol edilemez sonucunda yapılan restoratif tedavi başarısız olur (Hickel ve ark. 2010).

#### **2.2.2.2. BULANIK DENTİN (YUMUŞAK DENTİN)**

- Enfekte dentin tabakasına komşu olan tabakadır.
- Kollajen yapı yıkılmış, dentin tübüllerinin ve kanallarının yapısı bozulmuş ve mikroorganizmaların yoğunluğu artmıştır.
- Kollajen doku rehberlik yaparak intertübüler dentin yapısının remineralizasyonunu sağlar. Bu tabakada kollajenler deformasyona uğradığından remineralizasyon imkânı ortadan kalkar. Yapısal olarak bozulmuş dentin dokusunun bu sebepten restoratif materyal uygulanmadan önce tamamen kaldırılması gereklidir. (Hickel ve ark. 2010).

#### **2.2.2.3. TRANSPARAN DENTİN**

- Bu tabakada mikroorganizmalar yer almaz.
- Mikroorganizma yer almadığından kollajen bağlar sağlıklıdır.


- Sağlıklı kollajen bağlar ise bu tabakanın remineralizasyonuna olanak tanır.
- Subtransparan dentin dokusuna oranla demineralizasyon daha yoğundur bu sebepten dentin tübüllerinde daha büyük kristallere rastlanmaktadır. (Hickel ve ark. 2010).

#### **2.2.2.4. SUBTRANSPARAN DENTİN**

- Bu tabakada diğer çürük tabakalarına nazaran daha az yoğunlukta demineralizasyon gerçekleşmektedir.
- Demineralizasyon süreci odontoblast uzantılarına hasar verebilir buna rağmen bu tabaka da remineralizasyon yapabilir.
- Dentin kanalları içerisinde küçük boyutlu kristaller bulunmaktadır (Hickel ve ark. 2010).

#### **2.2.2.5. NORMAL DENTİN**

- Dentin kanallarında kristal bulunmaz.
- Odontoblast uzantıları normal seyrindedir.
- Kollajen bağları çok sağlamdır.
- Normal dentin dokusunda mikroorganizmalar bulunmaz.
- Normal dentine termal, osmotik ve mekanik uyaranlar iletilirse dişte hassasiyete sebebiyet verebilir (Hickel ve ark. 2010).



**Resim 2:** Dentin çürüğünün sınıflandırılması (Ogawa ve ark. 1983; Schwendicke ve ark. 2016)

### 2.2.3. PİT VE FİSSÜR ÇÜRÜKLERİ

Gıda artıkları ve diş plağı, fissürlerde birikir ve sert dokuların dekalsifikasyonuna yol açar. Sonuç olarak çürük lezyonlarına yol açan bakteriler asitle fermente olabilen karbonhidratlar üretir. Koni şeklindeki lezyon, dentinoenamel birleşimine doğru neredeyse dik olarak uzanır. Fissürler dentinoenamel birleşime lokalizasyon olarak yakın konumdadır bundan dolayı çürük hızlı bir şekilde dentine penetre olabilir (Goldberg 2016). Fissürlerde yapılan invaziv işlemlerden sonra bile debris ve pelikül bulunabileceği söylenmektedir (Salama ve Al-Hammad 2002).

Kompleks yapılarından dolayı okluzal pit ve fissür çürükleri en sık görülen çürük türlerindendir. (Hicks ve Flaitz 1993; Cehreli ve ark. 2006). Başlangıç mine çürükleri, fissürlerde veya derin okluzal invajinasyonlarda da gelişebilir. Okluzal fissürlerde morfolojik bir sınıflandırma bildirilmiştir (Goldberg 2016).

1. V tipi, üstte geniş ve fissürün dibine doğru giderek daralan tiptir. Okluzal fissürlerde bu lezyonların %34'ü söz konusudur.
2. U tipi, fissürün üstünde ve altında sabit bir genişlik gösterir (%14 )
3. I tipi, kasp tepeleri arasında dar bir boşluk olarak görülür (%19 ).

4. Altta daha büyük bir alanla ilişkili dar bir alana sahip IK tipi (%26 ).
5. Diğer türler (%7 ).

#### 2.2.4. İNTERPROKSİMAL ÇÜRÜKLER

Düz mine yüzeyleri genellikle plak retansiyonu için elverişli değildir; fakat interproksimal kontakt alanları ile gingivanın arasındaki düz yüzeyler plak formasyonu açısından tehlikeli yerlerdir. İnterproksimal yüzeyler ve interproksimal kontakt alanları plağın tutunmasını sağlayarak çürüğe daha yatkın yüzeyler haline gelirler (Kidd Edwina 2005).

Çürüğün evreleri lokalizasyonuna göre Lian ve arkadaşları tarafından dört grupta incelenmiştir (Lian ve ark. 2021).

**Tablo 1:** İnterproksimal Çürük Sınıflandırması (Lian ve ark. 2021)

| ÇÜRÜK<br>EVRELERİ | Çürük Lokalizasyonu                                                      |
|-------------------|--------------------------------------------------------------------------|
| D0                | Mine ve dentin sağlıklı                                                  |
| D1                | Mine veya dentinin dış üçte birlik kısmında çürük radyolüsensi           |
| D2                | Dentinin orta 1/3'üne uzanan çürük radyolüsensi                          |
| D3                | Görünür pulpa tutulumu olan veya olmayan derin dentin çürük radyolüsensi |

### 2.2.5. SEKONDER ÇÜRÜK

Sekonder çürükler, “mevcut restorasyonların kenarlarındaki lezyonlar” veya “restorasyonlar veya fissür sealantlar ile ilişkili çürükler” olarak tanımlanmıştır. Sekonder çürük, geleneksel çürüğün çeşitli nedenleriyle ilgili restorasyon ve restoratif materyalin belirli özellikleriyle iç içe geçiren kompleks, çok faktörlü bir süreçtir; yani sekonder çürük patogenezi, demineralizasyonu içeren diğer çürük lezyonları için aynı konsepti takip eder (Mjör ve Toffenetti 2000).

Sekonder çürükler hatalı bir restorasyonla (esas olarak restorasyon ve diş arasındaki boşluklar yoluyla bakterilerin oluşturduğu asitlerin veya biyofilmin ara yüze girmesine izin vererek) veya sağlam bir restorasyonla ilişkili olabilir. Örneğin, diş sert dokusuna kıyasla restorasyonun daha düşük tamponlama kapasitesi vardır. Restorasyondan bağımsız, sadece mevcut restorasyonlara bitişik primer çürükler olarak da karşımıza çıkabilir. Yine de her üç durum için de çürük gelişimi ile ilgili bilinen faktörler (karyojenik bir biyofilmin varlığı, fermente edilebilir karbonhidratların varlığı, mineral kaybı ve diş sert dokusunun kaybı) gereklidir (Ferracane 2017).

### 2.3. ÇÜRÜK TEŞHİS YÖNTEMLERİ

Diş hekimliğinde; zamanında, kesin ve doğru yapılan bir teşhis başarılı bir tedavi uygulamasının ilk adımıdır (Pitts 1997).

İdeal bir çürük teşhis yönteminden beklenen; hastalıklı ve sağlıklı dokuyu birbirinden kolayca ayırabilen, güvenilir, kolay uygulanabilen, hasta ve hekim tarafından kabul görmüş bir uygulama olmasıdır (Korkut ve ark. 2011).

**Tablo 2:** Çürük Teşhis Yöntemlerinin Sınıflandırılması (Korkut ve ark. 2011)

| <b>GELENEKSEL<br/>TEŞHİS<br/>YÖNTEMLERİ</b> | <b>MODERN YÖNTEMLER</b>                                    | <b>YENİ GELİŞTİRİLEN<br/>YÖNTEMLER</b>     |
|---------------------------------------------|------------------------------------------------------------|--------------------------------------------|
| Görsel Muayene                              | Dijital<br>Radyografiler                                   | Alternatif akım empedans<br>spektroskopisi |
| Ayna-Sond ile<br>Muayene                    | Lazer Floresans Kaynaklı<br>Yöntemler (QLF,<br>DIAGNOdent) | Ultrasonik sistem                          |
| Radyografik<br>Muayene                      | Elektriksel İletkenlik Ölçümleri                           |                                            |
|                                             | Fiber Optik Yöntemler                                      |                                            |
|                                             | Mikro Bilgisayarlı Tomografi<br>Yöntemi                    |                                            |

### **2.3.1. GÖRSEL MUAYENE**

Görsel muayene sırasında maksimum bilginin elde edilmesini sağlamak için dişlerin temiz, tamamen kuru ve iyi aydınlatılmış olması gerekir. Buna rağmen, çürükleri tespit etme çabası içinde makroskopik olarak sağlam okluzal yüzeylerin in vitro görsel muayenesi genellikle %30'un altında sınırlı duyarlılığa sahiptir (Lussi 1993).

Tecrübeli hekimler, borderline dentin çürüğü lezyonlarının tespisi için %60'ın üzerinde duyarlılık ve %80'in üzerinde özgüllük sağlayabilmektedirler (Downer 1989). Daha büyük lezyonların ve sağlam dişlerin dâhil olduğu bütün bir popülasyonda, görsel tanı yöntemlerinin duyarlılığı çok daha yüksektir. Daha kesin, spesifik görsel tanı kriterlerinin kullanılması, “gizli çürüklerin” daha doğru bir şekilde

tespit edilmesini sağlar ve önemli ölçüde daha iyi tanı hassasiyetleri sağlar (Ekstrand ve ark. 1997).

### **2.3.2. AYNA-SOND İLE MUAYENE**

Dental aynalar ve sondlarla yapılan muayene yöntemidir. Bir sondun kullanılmasının teşhisteki doğruluk oranını iyileştirdiği söylenemez. Takılan bir sond çürüğün kesin göstergesi değildir ve lokal anatomik özelliklerden kaynaklanabilir. Sondların yüzey bütünlüğüne hasar verdiği kanıtlanmış olduğundan ve mikroorganizmaların implantasyonunu arttırdığından, özellikle Avrupa ve İskandinavya'da, lezyon duyarlılığını artırabilen, keskin bir sondla basınç uygulaması tartışılmıştır (Ekstrand ve ark. 1987; Van Dorp ve ark. 1988).

Mikroorganizmaların dentin dokusunda daha derinlere taşınmasına neden olması, remineralize olma ihtimali olan mine dokusunda hasar oluşturabilmesi, başlangıç aşamasındaki çürük dokularının daha hızlı ilerlemesine yardımcı olması gibi dezavantajları vardır (Hicks ve ark. 2003; Gladwin ve ark. 2009).

Çürük dokusunun derinliğini belirleyemeyen bu yöntem, dişlerde kaviteasyon oluşturmadan meydana gelen çürüklerin teşhisinde tek başına yeterli olamamaktadır. Bu nedenle, diğer çürük teşhis yöntemleriyle birlikte kullanılması tavsiye edilir (Uzun ve Nazlıel 2000; McComb ve Tam 2001).

### **2.3.3. RADYOGRAFİK MUAYENE**

Diş radyografileri, gelişmiş ülkelerde yapılan en sık tanısal röntgen muayenesini temsil eder (Radiation 1988). Radyografik muayenenin temelini, X-ışınları gönderilen dişlerin ve sert dokuların radyogram üzerinde oluşturdukları görüntüler oluşturmaktadır. X-ışını çürük lezyonu olan dokulara oranla sağlıklı diş

dokuları tarafından daha fazla tutulmaktadır. X-ışını duyarlılığı bu yüzden sağlıklı doku ile çürükte farklıdır. Çürük ayrımı bu şekilde tespit edilebilir(Gündüz 2003; Pedrosa ve ark. 2011).

### **2.3.3.1. PANORAMİK RADYOGRAFİLER**

Panoramik radyografi ekstraoral görüntüleme yöntemlerindendir. Maksilla ve mandibuladaki dişleri, dişlerin komşuluğundaki anatomik yapıları bir görüntüde bir bütün halinde incelemek için kullanılan görüntüleme tekniğidir. (Newman ve Friedman 2003).

#### **Panoramik Radyografisinin Avantajları**

- Yüz kemiklerini, dişleri, dişlerin bulunduğu arkları ve komşu yapıları geniş bir biçimde göstermesi
- Trismus olan hastalarda ve intraoral teknikler uygulandığı zaman bulantı refleksi veren hastalarda kullanılması
- Pratik ve kullanışlı bir radyografi olması
- Diğer tekniklere göre uygulamasının daha kolay ve standart olması
- Full-mouth intraoral serisine göre totalde daha düşük radyasyon dozu ile görüntünün elde edilmesi
- Hasta eğitimi veya vakanın sunumunda kolay anlaşılır ve yararlı bir teknik olması

#### **Panoramik Radyografinin Dezavantajları**

- İntraoral tekniğe göre daha düşük çözünürlükte olması
- İntraoral tekniğe göre daha düşük detay içermesi
- Görüntülerde distorsiyon ve magnifikasyonlar nedeniyle ölçümlerin doğru sonuç vermemesi
- Uygulama esnasında hasta pozisyonlandırmanın çok dikkatli yapılması

- Görüntüde süperpozisyonlar nedeniyle anatomik yapıların değerlendirilmesi güçleşebilir (White ve Pharoah 2014).

### **2.3.3.2 BİTEWİNG RADYOGRAFİLER**

İntraoral radyografiler; panoramik radyografiden daha fazla ayrıntıyı göstermesi, doğru açılama ve teknik kullanıldığında magnifikasyon ve süperpozisyonların daha az olması sebebiyle panoramik radyografide emin olunmayan durumlarda doğru tanı koymak için ilave olarak kullanılır (Bozdemir ve Yarbasi 2019). Mevcut literatürün gözden geçirildiğinde çok fazla çürük lezyonunun gözden kaçırılmaması için, bir intraoral tekniği olan bitewing radyografi kullanılması gerektiği sonucuna varılmıştır (Kidd ve Pitts 1990; White ve Pharoah 2014).

## **2.4. YAPAY ZEKÂ**

Yapay zekâ, minimum insan müdahalesi ile akıllı davranışı modellemek için bir bilgisayarın kullanımını öngören genel bir terimdir. Yapay zekânın genel olarak robotların icadıyla başladığı kabul edilir. Bu terim, zorla çalıştırma olarak kullanılan biyosentetik makineler anlamına gelen Çekçe robota kelimesinden türemiştir (Hamet ve Tremblay 2017).

Yapay zekânın aslında birden çok tanımını yapmak mümkündür (Russell 2020). Nabyev insan zekâsının çözüm üretme, anlama, genelleme yapma ve geçmişteki deneyimlerden ders çıkarma gibi insana özgü yetenekleri modelleyerek bir bilgisayara ya da bilgisayar destekli bir makineye bu yetenekleri kazandırmak olduğunu söylemiştir (Nabyev 2012). Bellmann ise ‘Öğrenme, karar verme ve problem çözme içeren insan düşünme yetenekleriyle ilişkili etkinliklerin otomasyonu’ olarak tanımlamıştır (Bellman 1978).

### **İnsan gibi düşünen sistemler**

- Öğrenme, problem çözme ve karar verme gibi insan düşünme yetenekleriyle ilişkili etkinliklerin otomasyonunu içeren sistemlerdir (Bellman 1978).
- Bilgisayarların düşünmesini sağlayan gerçek zihinleri olan makinelerdir (Haugeland 1989).

### **İnsan gibi davranan sistemler**

- İnsanlar tarafından zekâ gerektiren eylemleri gerçekleştiren makineler oluşturan sistemlerdir (Kurzweil ve ark. 1990).
- Bilgisayarların günümüzde insanların daha üstün olduğu eylemleri nasıl yapacağını inceleyen sistemlerdir (Rich ve Knight 1991).

### **Rasyonel düşünen sistemler**

- Bilişimsel modellerin ışığında zihinsel yeteneklerin araştırıldığı sistemlerdir (Charniak ve McDermott 1985).
- Algılamayı, akıl yürütmeyi, harekete geçmeyi gerçekleştirebilecek hesaplamaların araştırıldığı sistemlerdir (Winston 1992).

### **Rasyonel davranan sistemler**

- Bilişimsel zekâ, akıllı ajanların mimarisinin araştırılmasını içeren sistemlerdir (Poole ve ark. 1998).
- Yapay zekâ, objelerdeki akıllı davranışlarla bağlantılıdır (Nilsson ve Nilsson 1998).

#### 2.4.1. YAPAY ZEKÂNIN KRONOLOJİK GELİŞİMİ

Son asırda çok popüler olan ve en mühim gelişmelerden olan yapay zekânın ortaya çıkışı antik Yunan ve eski Mısır dönemine dayanır. Yunan mitolojisine göre rüzgâr tanrısı olarak bilinen Daedalus'un “yapay-insan” benzetmesi ve Leonardo da Vinci'nin 1445'lerde yaptığı robot insan eskizleri yapay zekânın ilk çalışmalarındandır. Asırlar yıl öncesi geçmişten günümüze kadar yapay zekânın birçok başarısına veya başarısızlığına rastlanmaktadır (Russel ve Norvig 2010; Miladinović ve ark. 2017).

Yapay zekânın kökeni daha uzun bir geçmişe kadar izlenebilmiştir; fakat Alan Turing bilgisayar kullanma kavramını 1950'de tanımlamıştır (Miladinović ve ark. 2017; Kaul ve ark. 2020). İkinci Dünya Savaşı'ndan sonra 1956 yılında John McCarthy yapay zekâ kavramını “akıllı makineler oluşturma bilimi ve mühendisliği” şeklinde adlandırmıştır (Miladinović ve ark. 2017; Malik ve ark. 2019).

İlk zamanlarda yapay zekâ yalnızca bir insanın yapabileceği çıkarımlar veya kararlar verme yeteneğine sahip makinelerin geliştirilmesine odaklanmıştır. İlk endüstriyel robot kolu (Unimate), 1961'de General Motors'daki montaj hattına katılmıştır ve otomatik kalıp dökümü gerçekleştirmiştir (Moran 2007). Unimate, adım adım komutları takip edebilmiştir. Birkaç yıl sonra (1964) ise Eliza, Joseph Weizenbaum tarafından tanıtılmıştır. Doğal dili kullanan Eliza, insan konuşmasını (yüzeysel iletişim) taklit etmek için kalıp eşleştirme ve ikame metodolojisini kullanarak iletişim kurabilmiştir (Weizenbaum 1966).

1966 yılında “ilk elektronik insan” olan Shakey geliştirilmiştir. Stanford Araştırma Enstitüsü'nde oluşturulan bu robot talimatları yorumlayabilen ilk mobil robottu. Shakey, tek adımlık komutları takip etmek yerine, daha karmaşık talimatları işleyebilip uygun eylemleri gerçekleştirebilmiştir. Bu olay robotik ve yapay zekâda önemli bir ilerlemedir (Kuipers ve ark. 2017).

Mühendislikteki bu yeniliklere rağmen, tıp dünyası yapay zekâyı benimsemekte yavaş kalmıştır. Bununla birlikte, bu erken dönem, daha sonra temel olarak hizmet eden verilerin sayısallaştırılması için önemli bir zamandı. 1960'larda Ulusal Tıp Kütüphanesi tarafından Tıbbi Literatür Analizi ve Erişim Sisteminin ve web tabanlı arama motoru PubMed'in geliştirilmesi, biyotibbın daha sonra hızlanması için önemli bir dijital kaynak haline gelmiştir. Ayrıca klinik bilişim veri tabanları ve tıbbi kayıt sistemleri, ilk olarak bu süre zarfında geliştirilmiştir ve tıpta kullanılan yapay zekânın gelecekteki gelişmeleri için temel oluşturulmasına yardımcı olmuştur (Kulikowski 2019).

1970 ve 2000 yılları arası dönemde, yapay zekâya ilgi ve yatırım azalmıştır. Bu döneme gelişmelerin daha az olduğu anlamına gelen “Yapay Zekâ Kışı” denir (Pannala ve ark. 2020). Bu süre zarfında genel ilginin olmamasına rağmen, yapay zekâ alanındaki öncü kişiler arasındaki iş birliği devam etmiştir. Saul Amarel 1971'de Rutgers Üniversitesi'nde biyotıp alanında araştırma kaynağını bilgisayarlar üzerinde geliştirmiştir. Zaman paylaşımlı bir bilgisayar sistemi olan “Stanford Üniversitesi Tıbbi Deneyler-Tıpta Yapay Zekâ” kuruluşu 1973'te oluşturulmuştur ve çeşitli kurumlardan klinik ve biyomedikal araştırmacılar arasında ağ oluşturma yeteneklerini geliştirmiştir (Kulikowski 2015). Büyük ölçüde bu işbirliklerinin bir sonucu olarak, 1975'te Rutgers Üniversitesi'nde ilk tıpta yapay zekâ çalıştayını düzenlenmiştir (Kulikowski 2019). Bu gibi çalışmalar 1990'ların sonunda, özellikle tıp dünyasında, yukarıdaki teknolojik gelişmelerle birlikte modern tıpta yapay zekâ çağına zemin hazırlayan makine öğrenimine ilgi tekrardan artırmıştır (Shortliffe ve ark. 1975; Weiss ve ark. 1978; Martinez-Franco ve ark. 2018).

Doğal dil işleme olarak adlandırılan sistem, sohbet robotlarını yüzeysel iletişimden (Eliza) anlamlı konuşma tabanlı ara yüzlere dönüştürmüştür. Bu teknoloji 2011 yılında Apple'ın sanal asistanı Siri'ye ve 2014 yılında Amazon'un sanal asistanı Alexa'ya uygulanmıştır. Pharmabot, 2015 yılında pediatrik hastalar ve ebeveynleri için ilaç eğitimine yardımcı olmak üzere geliştirilmiş bir sohbet robotudur ve Mandy, bir birinci basamak uygulaması için otomatik bir hasta alım süreci olarak 2017'de oluşturulmuştur. Yapay zekâda çığır açan bu ve bunun gibi gelişmeler ise geçtiğimiz

20 yılda kaydedilmiştir. Bu gelişmeler göz önüne alındığında, gelişmiş bilgisayar donanımı ve yazılım programları ile birlikte dijitalleştirilmiş tıp daha kolay erişilebilir hale gelmiştir ve tıpta yapay zekâ hızla büyümeye başlamıştır (Comendador ve ark. 2015; Ni ve ark. 2017).

#### **2.4.2. YAPAY ZEKÂNIN AVANTAJLARI VE DEZAVANTAJLARI**

Yapay zekâ üzerine yapılan çalışmalar insan zekâsının taklit edilmesi sonucu olarak ortaya çıkar. Bu çalışmalar makinelerin doğal zekâ öğrenmelerini modellemesi olarak tanımlanabilir. Doğal zekâda öğrenme sikluslarının beyinde gerçekleştirildiği dikkate alındığında, beynin anatomisi ve fizyolojisi incelenerek makineler üzerinde taklit edilmesi mümkün görülmektedir. Doğal zekâda öğrenme fizyolojisi nöron olarak adlandırılan beyin hücrelerindeki iletişimler aracılığıyla oluşur. Bundan esinlenerek bilgisayarlarda da yapay sinir ağları icat edilmiştir. Böylece öğrenme olayı taklit edilmiştir (Yılmaz ve Kaya 2021).

##### **Yapay Zekânın Avantajları**

- Yapay zekâ incelemelerinin ve araştırmalarının öncülerine göre doğada öğrenme fizyolojilerinin ve anatomilerinin bütün detaylarının anlaşılması ve tanımlanması yapıldığında makineler bu işleyişi taklit ederek öğrenme yeteneği ve zekâyâ sahip olabileceklerdir (McCarthy 2007).
- Yapay zekâ doğal zekâdan esinlenerek öğrendikleri girdileri hemen işleyip çıktıya dönüştürebilmektedir ve öğrenmeyi sürekli hale getirebilmektedir (Öztürk ve Şahin 2018).
- Matematik ve istatistik bilimleri yapay zekâ kullanan makinelere öğrenme yeteneği kazandırmıştır. İnsanlığın yıllarca yaşasa ancak

tecrübe edebileceği tecrübeleri ve öğrenimleri yapay zekâ sistemleri matematik ve istatistik gibi bilimler aracılığıyla hızla kazanabilmektedir (Kılınç ve Başeğmez 2019).

- Yapay zekâ kendisine tanıtıldığı şekilde problemlere cevap verir. Bu yüzden bir problemle karşılaştığında tutarlı tepkiler verir ve karşılaştığı her koşula verdiği tepki aynıdır.
- Yapay zekâda veriler kalıcıdır çünkü depolanır.
- Yapay zekâda verilerin aktarılması, raporlanması, belgelenmesi ve kopyalanması bilgiler depolandığı için kolaydır.
- Yapay zekânın eğitilme süresi doğal zekâyı oranla kısadır. Yapay zekânın eğitim süresi en fazla saatler günler olurken doğal zekânın eğitimi yılları bulmaktadır (Cross 1999; Harun 2006; Nabiyeve 2012; Shabbir ve Anwer 2018; Pandl ve ark. 2020).

### **Yapay Zekânın Dezavantajları**

- İnsan beyni, verileri kaydedip komuta dönüştüren bilgisayara benzetilmiştir. İnsanlarla bilgisayarlar karşılaştırıldığında önemli farklar bulunmuştur. Bu farklardan en önemlisi, insan beyninde birçok komut milyonlarca nöronla aynı anda yürütülebilirken bilgisayarlarda komutların işlemcilerde sırasıyla işlenmektedir (Say 2018).
- Yapay zekâ kullanan makineler son dönemde önemli ölçüde gelişme kaydetmiş olmasına rağmen doğal zekânın hayal gücü, özgüllük ve yaratıcılık yeteneklerini halen sistemlerine kazandıramamışlardır (Sariel 2017).

- Yapay zekâda verinin tek kaynağı insan olduğundan yapay zekâ yenilikçi ve yaratıcı değildir, çevreden etkilenmez. Müdahale olmadan kendini güncellemez.
- Yapay zekâ eğitildiği kadar tecrübelidir. Tüm deneyimi eğitim verisi kadardır. Spontane ve daha önce karşılaşılmamış sorunları yanıtlamakta yetersizdir (Cross 1999; Harun 2006; Nabyev 2012; Shabbir ve Anwer 2018; Pandl ve ark. 2020).

### **2.4.3. YAPAY ZEKÂ TEKNİKLERİ**

Yapay zekâ teknikleri, sistemleri modellemek için klasik tekniklere alternatif olarak giderek daha fazla kullanılmaktadır (Chen ve ark. 2008).

#### **2.4.3.1. UZMAN SİSTEMLER**

Yapay zekânın alt başlıklarındandır. Uzman sistem, tespit edilen sorunun çözümüyle alakalı uzmanların tecrübe, bilgi ve yeteneklerini kullanan bilgisayar sistemleridir (Allahverdi 2002).

Uzman sistemlerin yaygınlaşmasının iki ana nedeni vardır:

- Uzmanların uzmanlıklarını diğer personele aktarmak
- Kurumdan ayrılacak uzmanların bilgilerinin korunması ve saklanması.


Uzman sistemler aslında uzmanların muhakeme süreçlerini simüle etmek için tasarlanmıştır (Caldeira 2007). Uzman sistem kavramı, uzmanların alan bilgilerini bir bilgisayar sistemine girilebileceği ve gerektiğinde geri alınabileceği varsayımına dayanmaktadır. Sistemin işlevi, alan bilgi tabanlarına, çözülecek problem hakkındaki gerçeklere ve muhakeme mekanizmalarına dayanmaktadır (Kunhimangalam ve ark. 2014).

Uzman sistemler 3 ögenin bileşenlerinden yaratılmıştır:

- Parametreler ve Kurallar
- Veri Tabanı
- Sonuç Mekanizması

Uzman sistemlerin yazılımı ise bu üç bileşenlerin alanında mühendis olan uzmanlar tarafından gerçekleştirilir. Uzman sistemlerin yapıtaşlarından olan veri tabanı, uzmanların da ortak bir kaniya vardığı tartışmasız gerçeklerden oluşturulur. Veri tabanı uzmanların acemi olduğu konularda ise çözüm süreci için gerekli mühim veri ve kanunlardan oluşur. Verilerin en yaygın işlenilen temsili, koşullu önerme şeklindeki kurallardır. Uzman sistemler ise yaygın olarak basit mekanizmalar için kullanılmışlardır. Bu şekilde uzman sistemler bazı alanlarda başarılı olmuştur; ancak uzman sistemlerin halen birçok alanda yetersiz kaldığı bildirilmiştir (Tuzcuoglu 2003).

Uzman sistemler uzmanların yerini doldurmaktan ziyade uzmanın noksan olduğu durumlarda ihtiyaç duyulan desteği verir. Problemlerin hızla etkili ve verimli bir şekilde çözülmesine yardımcı olur (Babalık ve Güler 2007). Ses tanıma, görüntü analizi, hava tahmini, tıp, elektronik devre çizimi, ürün tasarımı, otomatik programlama, nükleer güç santrali, bilgisayar yazılımı, otomobil, bilgisayar gibi alanlarda da bu doğrultuda uzman sistemler kullanılmaktadır (Allahverdi 2002).



Şekil 1: Uzman Sistemlerin Şematize Edilmesi (Serhatlıoğlu ve Hardalaç 2009)

## Tıp Alanında Kullanılan Uzman Sistemler

Klinikte karar verme aşaması, bazı komplike olayları beraberinde getirir. Tıp alanındaki verilerin çokluğu ve insan hayatıyla ilgili klinik kararların içsel karmaşıklığı, uzmanları tıpta yapay zekâ sistemlerini kullanmayı düşünmeye sevk etmiştir. Bu nedenle, hastalıkların teşhis ve tedavisinde farklı yapay zekâ sistemlerinin kullanımına ilişkin birçok araştırma yapılmaktadır. Bu çalışmalar, uzman sistemlerin performansını, vaka tabanlı akıl yürütmeyi, yapay sinir ağlarını, genetik algoritmaları, bulanık mantığı ve bulanık sinir ağları, bulanık uzman sistemler vb. gibi farklı sistem ve tekniklerin kombinasyonunu incelemiştir (Schmidt ve Gierl 2001; Goletsis ve ark. 2004; Chi ve ark. 2008; Sharaf-El-Deen ve ark. 2014).


Tıpta ilk yardım kalitesinin artırılması (Ertl ve Christ 2007), nöropatilerin tipinin belirlenmesi (Kunhimangalam ve ark. 2014), baş ağrısı türlerinin tespiti (Maizels ve Wolfe 2008), kalp ritmindeki değişikliğin tespiti (Exarchos ve ark. 2007) gibi konularda uzman sistemler kullanılmıştır.

Klinik karar verme, hastalıkların teşhisi ve tedavisi karmaşık işlerdir ve bazı durumlarda uzmanlar bile bir anlaşılmaya varamamışlardır. Yapay zekâ sistemleri bu konuda doktorlar için çok yardımcı olabilir (Sheikhtaheri ve ark. 2014).

### 2.4.3.2. BULANIK MANTIK

Prof. Dr. Lotfi A. Zadeh 1965'te California Berkeley Üniversitesi'nde ilk yayınıyla bulanık mantığı tanıtmıştır. Bulanık mantık insanların bilgi ve tecrübelerini sistemlere aktararak sistemlere bu şekilde işleme özelliği kazandırır. İfadelerin bilgisayar sistemlerindeki karşılığı rakamlarla olmaktadır. Klasik mantık (0-1) olarak iki net değer alabilirken; bulanık mantık ise [0-1] aralığında birçok ara değerleri de alabilir. Bulanık mantık siyah beyaz yerine birçok gri tonundan bahseder. Bulanık mantık modern çağımızda gittikçe önem kazanır. Bunun sebebi felsefe, mantık ve aynı

zamanda sosyal alanlara çözümler bulmasıdır. Ayrıca dünyada aslında olgu, olay ve kararların siyah/beyaz, doğru/yanlış gibi net sınırlarla ayıramayacağını bulanık mantık bizlere anlatmaktadır. Günümüzde ev aletleri, elektronik eşyalar ve birçok alanda bulanık mantıkla çalışan yapay zekâ teknolojisine rastlanmaktadır (Harun 2006; Keskenler ve Keskenler 2017).



Şekil 2: Bulanık Mantığın Şematize Edilmesi (Serhatlıoğlu ve Hardalaç 2009)

### Tıp Alanında Kullanılan Bulanık Mantık

Tıbbi uygulamaların karmaşıklığı, geleneksel nicel analiz yaklaşımlarını uygunsuz hale getirir. Tıpta, bilgi eksikliği ve belirsizliği ve çoğu zaman tıbbın çelişkili doğası yaygın gerçeklerdir (Abbod ve ark. 2001).

Belirsizliğin kaynakları aşağıdaki gibi sınıflandırılabilir (Marchais 2002) :

- 1) Hasta hakkında bilgiler.
- 2) Genellikle hasta ve/veya ailesi tarafından sağlanan hastanın tıbbi öyküsü. (Tıbbi öykü ise genellikle son derece öznel ve kesin değildir.)
- 3) Fizik muayene. (Hekim genellikle nesnel veriler elde eder, ancak bazı durumlarda normal ve patolojik durum arasındaki sınır keskin değildir.)

- 4) Laboratuvar ve diğer tanısal testlerin sonuçları.
- 5) Hasta anamnez verirken hekimi yanlış yönlendirebilir.

Borderline vakalarda sınıflandırma, özellikle kategorik bir teşhis sistemi düşünüldüğünde zordur. Bulanık mantık tıpta önemli bir rol oynar (Abbod ve ark. 2001; Barro ve Marín 2001). Bulanık mantığın birçok noktayı aştığını gösteren bazı örnek hastalık grupları aşağıdaki gibidir:


- 1) Sitalopram ile tedaviye yanıtı tahmin etmek alkol bağımlılığında kullanılır (Naranjo ve ark. 1997).
- 2) Diyabetik nöropatiyi ve retinopatiyi analiz etmek ve erken teşhis etmek için kullanılır (Di Lascio ve ark. 2002).
- 3) Uygun lityum dozunu belirlemek için kullanılır (Di Lascio ve ark. 2002).
- 4) Manyetik rezonans görüntüleme (MRG) beyin dokusu hacimlerini hesaplamak ve fonksiyonel analizleri yapmak için kullanılır (Brandt ve ark. 1994).
- 5) Felç alt tiplerini ve birlikte var olan nedenleri karakterize etmek için kullanılır (Dickerson 1997).
- 6) Radyoterapiye karar vermek için kullanılır (Papageorgiou ve ark. 2003).
- 7) Anestezi sırasında hipertansiyonu kontrol etmek için kullanılır (Oshita ve ark. 1994).
- 8) Meme kanserini, akciğer kanserini ve prostat kanserini teşhis etmek için kullanılır (Seker ve ark. 2003).
- 9) Merkezi sinir sistemi tümörlerinin (astroitik tümörler) teşhisine yardımcı olmak için kullanılır (Belacel ve Boulassel 2004).
- 10) İyi huylu deri lezyonlarını malign melanomlardan ayırt etmek için kullanılır (Belacel ve Boulassel 2004).

### 2.4.3.3.YAPAY SİNİR AĞLARI (YSA)

YSA; sinir sistemi hücrelerinin yapısından ve fizyolojisinden esinlenerek geliştirilmiştir. YSA'ya milyonlarca bağlantıları olan aynı zamanda hepsinin kendi belleğine ait işlemcilerinden oluşan paralel işleme yapıları da denebilir. Başka bir tanımla biyolojik sinir ağlarının işleyişini kopyalayan bilgisayar sistemleridir (Elmas 2003).

Son yirmi yıldaki yayın yoğunluğuna bakılırsa, YSA tıpta en popüler yapay zekâ tekniğidir (Steimann 2001). YSA'lar biyolojik sinir sisteminden ilham alan hesaplamalı analitik araçlardır. Veri işleme ve bilgi temsili için paralel hesaplamalar yapabilen, 'nöronlar' olarak adlandırılan yüksek düzeyde birbirine bağlı bilgisayar işlemcilerinden oluşan ağlardan oluşurlar.

Tarihsel örneklerden öğrenme, doğrusal olmayan verileri analiz etme, kesin olmayan bilgileri işleme ve modelin bağımsız verilere uygulanmasını sağlayarak genelleştirme yetenekleri, YSA'yı tıp alanında çok çekici bir analitik araç haline getirmiştir.




Şekil 3: Yapay Sinir Ağları (Kirişçi 2019)

McCulloch ve Pitts, basit ikili eşik fonksiyonlarını kullanarak ilk yapay nöronu icat etmiştir (McCulloch ve Pitts 1990). Bir sonraki önemli dönüm noktası, bir psikolog olan Frank Rosenblatt'ın 1958'de Perceptron'u pratik bir model olarak geliştirmesidir. Temel Perceptron ağının birçok varyasyonu önerilmiştir ancak en popüler model çok katmanlı ileri beslemeli Perceptron olmuştur (Rosenblatt 1958).

#### 2.4.3.3.1. Yapay Sinir Ağlarının Mimarileri

YSA; sinir sistemi hücrelerinin yapısından ve fizyolojisi taklit edilerek oluşturulmuştur. Nöronlar kendi aralarında sinapslar aracılığıyla iletişim içerisindeyler. Sinir hücreleri işlediği verileri aksonlar aracılığıyla diğer hücelere iletirler. Doğadaki işleyişe benzer bir şebeke sistemi vardır. Bu şebekedeki elemanlar verileri toplar ve aktivasyon fonksiyonu işlemine tabii tutar. Aktivasyon fonksiyonundan geçen çıktılar oluşturarak bağlantıları sayesinde diğer yapay sinir hücrelerine gönderir (Öztemel 2012).



Şekil 4: Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo, Honório, da Silva, & applications, 2013)

**Tablo 3:** Biyolojik Sinir Sistemi Elemanları ve Yapay Sinir Sisteminde Karşılıkları (Öztürk ve Şahin 2018)

| <b>Biyolojik Sinir Sistemi</b> | <b>Yapay Sinir Sistemi</b> |
|--------------------------------|----------------------------|
| Nöron                          | İşlemci Elemanı            |
| Dendrit                        | Toplama Fonksiyonu         |
| Hücre Gövdesi                  | Transfer Fonksiyonu        |
| Aksonlar                       | Yapay Nöron Çıkışı         |
| Sinapslar                      | Ağırlıklar                 |

#### **2.4.3.3.2. Yapay Sinir Ağlarının Sınıflandırılması**

YSA yapıları, nöronların birbiriyle kurdukları bağların yönüne göre veya ağdaki verilerin akış yönlerine göre iki sınıfta incelenmektedir (Rojas 2013):


- İleri beslemeli (feed forward) ağlar
- Geri beslemeli (feedback, recurrent) ağlar

##### **2.4.3.3.2.1. İleri Beslemeli (Feed Forward) Yapay Sinir Ağları**

İleri beslemeli topolojiye sahip yapay sinir ağı, ileri beslemeli yapay sinir ağı olarak adlandırılır. Bilgi, geri döngü olmadan yalnızca bir yönde girdiden çıktıya aktarılmalıdır. Katman sayısı, bireysel yapay nöronlarda kullanılan transfer fonksiyonunun türü veya bireysel yapay nöronlar arasındaki bağlantı sayısı konusunda herhangi bir sınırlama yoktur. En basit ağlardan olan ileri beslemeli yapay sinir ağı, yalnızca doğrusal ayrılabilir problemleri öğrenebilen tek bir algılayıcıdır (Krenker ve ark. 2011).

Çok Katmanlı Algılayıcılar (Multilayered Perceptrons-MLP) ve Öğrenme Vektör Nicelendirmesi (Learning Vector Quantization-LVQ) ağları da ileri beslemeli ağlara örnek verilebilir (Sağıroğlu ve ark. 2003).

- **Tek Katmanlı Algılayıcılar:** Tek katmanlı ağlar yalnızca girdi ve çıktıdan oluşur. Bu algılayıcılarda çıktı fonksiyonu doğrusaldır. 1 ya da -1 değerlerinden başka bir değer yoktur. Çıktı 1 olduğunda birinci sınıf grubuna dâhil olur; ancak çıktı -1 ise ikinci sınıfa dâhildir.
- **Çok Katmanlı Algılayıcılar:** Bu algılayıcılarda çıktı fonksiyonu doğrusal değildir; aktivasyon fonksiyonu bulunur. Birçok yapay sinir hücresinin belirli bir üstünlükte bağlandığı yapıya çok katmanlı algılayıcılar denir. Bazı yöntemler etkisiz kaldığı için rolü çok katmanlı algılayıcılar ortaya çıkmaktadır (Öztürk ve Şahin 2018).



Şekil 5: Çok Katmanlı Algılayıcının Yapısı (Sağıroğlu ve ark. 2003)

#### 2.4.3.3.2. Geri Beslemeli (Feedback, Recurrent) Yapay Sinir Ağları

Geri beslemeli yapay sinir ağlarında bir nöronun çıktısı kendinden sonra gelen nöron katmanına girdi olarak işlenmesinin yanı sıra kendi katmanında veya kendinden

önceki katmanlarda bulunan nöronlara girdi olarak işlenebilir. Bu durum geri beslemeli yapay sinir ağlarının ileri beslemeli yapay sinir ağlarından farklıdır. Bundan dolayı geri beslemeli yapay sinir ağlarının vektörü doğrusal olmayan dinamik bir davranış sergilemektedir. Geri beslemeli yapay sinir ağları, segmentasyonu kaldırma ve örüntü tanıma (el yazısı tanıma) gibi görevlerde uygulanabilir. Geri beslemeli sinir ağı uygulama alanları arasında matematiksel kanıtlar, sismik veri uydurma, tıp, bilim, mühendislik, sınıflandırma, fonksiyon tahmini ve zaman serisi tahmini gibi alanlar bulunur (Kabalcı 2014; Albawi ve ark. 2017).

#### 2.4.3.3. Yapay Sinir Ağları Uygulamaları

YSA'lar, değişkenlerin ve parametrelerin söz konusu olduğu ve parametrelerin birbiriyle ilişkili olduğu herhangi bir durumda kullanılabilir. Bununla birlikte, YSA'lar, parametreler birbirleriyle karmaşık bir ilişkiye sahip olduğunda kullanılabilirler. Bayesian statistiğiyle bağlantılı sinir ağlarını kullanan birçok uygulama da vardır. Mevcut veriler verilen model parametrelerinin olasılık yoğunluğunu tahmin edebilir (Zrimec ve Kononenko 1999).

Uygulamalar üç geniş kategoriye ayrılır:

**Yorum:** Veriler toplanır ve ağa sunulur; ağ, sistemin durumunu tanımlayan değişkenler açısından doğrudan yorumlanabilen bir çıktı üretir (Stubbs 1990).

**Geliştirme:** Veriler toplanır ve ağa sunulur; ağ, görüntüyü veya sinyali geliştirmek için kullanılacak bir çıktı üretir, böylece yorumlamaya yardımcı olur. Geliştirme, hem orijinal verilerle birlikte görüntülenecek yeni bilgilerin oluşturulmasını hem de gürültülü verilerden yeniden yapılandırmayı kapsar (Stubbs 1990).

**Sıkıştırma:** İletim veya depolama için verileri sıkıştırmak için sinir ağlarını kullanma; ağ öğretildikten sonra, bir görüntüdeki tüm bilgileri gizli katman nöronlarının aktivasyon seviyeleri olarak temsil edebilir. Girdilerden daha az gizli katman nöronu varsa, görüntü sıkıştırılır (Stubbs 1990).

#### **2.4.3.3.4. Tıp Alanında Kullanılan Yapay Sinir Ağları**

YSA'lar hâlihazırda günümüz dünyasında kendisine çok çeşitli uygulamalar bulmuştur. Kalıpları doğru bir şekilde sınıflandırma ve tanıma yetenekleri, araştırmacıları birçok klinik problemin çözümünde uygulama konusunda cezbetmiştir.

Birçok klinik durumda tanı, tedavi ve sonucun tahmin edilmesinin birçok klinik, biyolojik ve patolojik değişken etkileşime bağlı olduğu bilinmektedir. Bu değişkenler arasındaki karmaşık ilişkilerden yararlanabilen YSA gibi analitik araçlara artan bir ihtiyaç vardır. YSA, tıp alanında da hızla yeni uygulama alanları ortaya koymaktadır. Tanıda yaygın uygulamaya ek olarak, görüntü işleme ve yorumlamanın yanı sıra sinyal işleme ve analizinde de birçok geliştirme çalışması yapılmaktadır. Tıp bilimindeki sinir ağı uygulamalarının diğer ana alanı olan bilgisayar destekli tanı, Stubbs tarafından kapsamlı bir şekilde gözden geçirilmiştir (Stubbs 1990).

YSA'nın geliştirilmesi sayesinde YSA birçok tıbbi veri analizinde kullanılmıştır. Bunlara örnek akciğer direkt radyografileri, ultrason taramaları, tomografik yöntemler verilebilir. Empedans tomografisini içeren bilgisayarlı tomografi, manyetik rezonans görüntüleme YSA ile daha düşük çözünürlük ve düşük maliyet imkanı sunar. Son olarak, zamanla biyoelektrik (veya biyomanyetik) değişikliklere dayanan EKG, EEG ve EMG gibi tanı teknikleri vardır (Stubbs 1990).

YSA otomotiv, bankacılık, savunma, finans, üretim, dil ve güvenlik modeli gibi pek çok sektörde de yaygın olarak kullanılmaktadır (Aytekin ve ark. 2019).

#### 2.4.3.3.5. Yapay Sinir Ağlarında Öğrenme

YSA'nın öğrenme kabiliyetinin olması en ayırt edici yönüdür. Mevcut örneklerin içeriğindeki yapının olumlu davranış sergilemesini gerçekleştirebilecek bağlantıların ağırlıklarının hesaplanması öğrenmenin açıklamasıdır. YSA öğrenme sırasında elde ettiği bilgileri, YSA'daki bağlantı ağırlıkları olarak saklar. Saklanan ağırlıklarda YSA'nın verileri sağlıklı bir biçimde kullanabilmesi için lazım olan bilgiler bulunur (Şen 2004).

YSA'da öğrenmenin temelini örneklerden öğrenme oluşturur. Örneklerden öğrenmenin mantığı bir hadisede yaşanan örnekleri kullanarak gerçekleşen hadisedeki girdi veriler ve çıktı veriler arasındaki bağlantıyı çözmektir ve bu bağlantılara ilişkin sonrasında ortaya çıkan örneklerin çıktılarını tespit etmektir. Aynı zamanda bu bağlantılar temsili bilgileri de içerir. Farklı örneklerin olayları farklı açılardan gösterdiği varsayılmaktadır. YSA'da öğrenmede yalnızca örnekler kullanılmakta olup örnekler dışında ön bilgi bilgisayara verilmemektedir. Öğrenmenin gerçekleşmesi için sistem aradaki ilişkiyi algoritmasını kullanarak bulmalıdır (Öztemel 2006).

YSA'ların öğrenmesine ilişkin iki yöntem vardır (Anderson 1992):

- Denetimli (supervised) öğrenme
- Denetimsiz (unsupervised) öğrenme

Denetimli öğrenme en sık kullanılan öğrenme yöntemidir. Bu yöntemde örnek olması için bir çıktı yapay sinir ağlarına verilir. Bu çıktı ile YSA'nın oluşturduğu çıktı karşılaştırılmakta olup aradaki fark hata olarak tanımlanır (Anderson 1992).

#### 2.4.3.4. GENETİK ALGORİTMALAR

Genetik algoritma tekniği, 1970'li yıllarda ortaya çıkan tabiattaki evrim yöntemlerini kullanan bir arama yöntemidir (John 1992). 1975'te John Holland

‘Doğal ve Yapay Sistemlerin Uygulanması’ isimli eserini çıkarmıştır. Mekanik öğrenme alanında yoğunlaşan Holland aynı zamanda Darwin’in evrim teorisinden de etkilenmiştir (John 1992; Öznur ve Korukoğlu 2003).

Genetik algoritma;

- Sistemleri parametre kümelerini kodlayarak çalışır.
- Amaç fonksiyonu bilgisini kullanır.
- Doğal genetik ve doğal seleksiyon mekaniğini temele alan olasılıksal bir arama yöntemidir.

Doğada daha güçlü tarafın yaşamına devam etme kuralına dayanır. Bütünü bir anda yakalamaya ve kavramaya yönelen düşünme yoluna sezgisel denilmektedir. Bu düşünce yolunu temel alan genetik algoritma klasik çözüm teknikleriyle çözülmesi zor olan problemlere uygulanmıştır. Sonucu tatmin edici olmuştur (Man ve ark. 2001).

#### **2.4.4. MAKİNE ÖĞRENİMİ**

Makine öğrenimi, 1959'da Arthur Samuel'e göre bilgisayar biliminin alt alanıdır ve bilgisayarlara açıkça programlanmadan öğrenme yeteneği verir (Baydan 2021). Makine öğrenimi hesaplamalı öğrenme teorisinden ve örüntülü tanıma teorisinden geliştirilmiştir. Makine öğrenimi, verilerle eğitilen ve veriler hakkında yaklaşık olarak değerlendirilebilen algoritmaları ve bu algoritmaların geliştirilmelerini araştırır. Bahsedilen algoritmalar, örnek verilerden bir model oluşturarak, veriye dayalı tahminler ya da kararlar vererek kesinlikle statik program talimatlarını takip eder (Kohavi 1998).

Makine öğrenimi, iyi performansa sahip açık algoritmalar tasarlamamanın ve programlamamanın zor veya mümkün olmadığı bir dizi hesaplama görevinde kullanılır; örnekler arasında e-posta filtreleme, optik karakter tanıma, sıralamayı öğrenme ve bilgisayar görüşü yer alır (Wernick ve ark. 2010; Ongsulee 2017).

Makine öğrenimi, bilgisayar kullanımı yoluyla tahmin yapmaya da odaklanan hesaplama istatistikleriyle yakından ilişkilidir. Makine öğreniminde kullanılan teknikler; teoride ve pratikte matematiksel optimizasyonla sistematik olarak problemi incelemektedir (Mannila 1996).

Makine öğrenim uygulamaları, tam olarak programlanmadan verilerden öğrenebilir; çeşitli araçları kullanarak tahminler ve önerilerde bulunabilir ve bilgisayar uygulamalarının performanslarının iyileştirmesini sağlar (LeCun ve ark. 2015). Günümüzde kullanılan çeşitli makine öğrenmesi yöntemleri arasında internet aramaları, e-ticaret, mal ve hizmet tavsiye sistemleri, görüntülerin tanımlanması, görüntü ve konuşma tanıma, sensör teknolojileri, robotik cihazlar bulunmaktadır (Davenport ve Ronanki 2018). Bu uygulamaların tamamı, bir makine tarafından öğrenmeyi sağlayan birkaç farklı makine öğrenimi teknikleri ile geliştirilmiştir (Gershman ve ark. 2015).


#### **2.4.5. DERİN ÖĞRENME**

Derin öğrenme (ayrıca derin yapılandırılmış öğrenme, hiyerarşik öğrenme veya derin makine öğrenimi olarak da bilinir), birden fazla gizli katman içeren yapay sinir ağları ve ilgili makine öğrenimi algoritmalarının incelenmesidir.

- Bu derin ağlar birçok doğrusal olmayan işlem birimi katmanından oluşan bir basamaklama kullanır. Her ardışık katman, önceki katmandaki çıktıyı girdi olarak kullanır. Algoritmalar denetlenebilir veya denetimsiz olabilir ve uygulamalar desen analizi (denetimsiz) ve sınıflandırma (denetimli) içerir (Deng 2014).
- Bu derin ağlar, verilerin birden fazla özellik düzeyinin veya temsilinin (denetimsiz) öğrenilmesine dayanır. Üst düzey özellikler, hiyerarşik bir temsil oluşturmak için alt düzey özelliklerden türetilir (Deng 2014).

- Bu derin ağılar, verilerin öğrenme temsillerinin daha geniş makine öğrenimi alanının bir parçasıdır (Deng 2014).
- Bu derin ağılar, farklı soyutlama seviyelerine karşılık gelen çoklu temsili seviyeleri öğrenir; seviyeler bir kavram hiyerarşisi oluşturur (Deng 2014).
- Basit bir durumda, iki nöron kümesi olabilir. Bu nöron kümeleri giriş sinyali alan ve çıkış sinyali gönderen kümelerdir. Giriş katmanı bir girdi aldığı anda, girdinin değiştirilmiş bir sürümünü bir sonraki katmana geçirir. Derin bir ağda, giriş ve çıkış arasında birçok katman vardır (Katmanlar nöronlardan oluşmaz, ancak bu şekilde düşünmeye yardımcı olabilir.). Bu katmanlar algoritmanın çoklu işlem katmanlarını kullanmasına izin verir, çoklu doğrusal ve doğrusal olmayan dönüşümlerden oluşur (Goodfellow ve ark. 2016).

Derin öğrenme metodlarının yapısındaki gizli katman sayısının fazla olması daha çok tercih edilmesini ve daha yüksek performans sergilemesini sağlamıştır (Goodfellow ve ark. 2016).



**Şekil 6:** Derin öğrenme metodunun diğer yapay zekâ teknikleriyle olan ilişkisi

Derin öğrenme, verilerin öğrenme özelliğini temel alan daha geniş bir makine öğrenme yöntemleri ailesinin bir parçasıdır. Bir gözlem (örneğin, bir görüntü), piksel

başına yoğunluk değerlerinin bir vektörü gibi birçok yolla veya daha fazla bir şekilde temsil edilebilir. Derin öğrenmenin amaçlarından biri, insan kaynaklı yapımları özellikleri denetimsiz veya yarı denetimli özellik öğrenme ve hiyerarşik özellik çıkarma için verimli algoritmalarla değiştirmektir (Song ve Lee 2013; Glauner 2015).

Bu alandaki araştırmalar, daha iyi çalışmalar yapmaya ve bu örnek çalışmaları büyük ölçekli etiketlenmemiş verilerden öğrenmek için modeller oluşturmaya çalışır (Barhoom ve Abu-Naser 2022).

Çalışmalardan bazıları nörobilimdeki ilerlemelerden esinlenmiştir. Çeşitli uyaranlar ve beyindeki ilişkili nöronal tepkiler arasındaki ilişkiyi tanımlamaya çalışan sinirsel kodlama gibi bir sinir sistemindeki bilgi işleme ve iletişim kalıplarının yorumlanmasına dayanmaktadır (Olshausen ve Field 1996).

Derin sinir ağları, bilgisayarla görme, otomatik konuşma tanıma, doğal dil işleme, ses tanıma ve biyoinformatik gibi alanlara çeşitli görevlerde uygulanmış ve son teknoloji sonuçlar ürettikleri gösterilmiştir.

Derin öğrenme sinir ağlarının yeniden markalaşması olarak nitelendirilmesine rağmen, derin sinir ağları, bilgisayar görüşü alanında nesne tanıma gibi görevlerde diğer makine öğrenimi algoritmalarından daha iyi performans gösterme yeteneği göstermiştir (Krizhevsky ve ark. 2017).

#### **2.4.5.1. Derin Öğrenme Metodları**

Derin öğrenme, 2006'da geliştirilmiştir. Doğrusal olmayan bilgi işlemenin birçok aşamasında model sınıflandırması ve özellik öğrenme için kullanıldığı bir makine öğrenme teknikleri sınıfını ifade eder. Üst düzey kavramların alt düzey kavramlardan tanımlandığı ve aynı alt düzey kavramların üst düzey kavramları tanımlamaya yardımcı olduğu bir özelliğe sahiptir. Sinir ağları, grafik modelleme,

optimizasyon, örüntü tanıma ve sinyal işleme araştırma uygulama alanlarından bazılarıdır (Markoff 2012; Deng 2014).

- Konvolüsyonel sinir ağları
- Tekrarlayan sinir ağları
- Sınırlı boltzmann makineleri
- Uzun kısa vadeli bellek ağları
- Derin oto-kodlayıcılar
- Derin inanç ağları

#### **2.4.5.1.1. Konvolüsyonel Sinir Ağları- KSA (Convolutional Neural Network-CNN)**

KSA ilk olarak 1980’de Kunihiko Fukushima tarafından geliştirilmiştir (Fukushima 1980). Daha sonra 1989’da Yann Le Cun el yazısı rakamları ve belge tanıma için KSA’yı geri yayılım teorisiyle birleştirmiştir (LeCun ve ark. 1989). Le Cun geliştirdiği sistemi elle yazılmış çekleri ve posta kodlarını okumak için kullanmıştır. KSA’da, evrişimli katmanlar ve havuzlama katmanları kullanılmaktadır. Evrişimli katmanlar girdi verileri filtrelemektedir. Belirli bir görevde kullanılacak bilgileri çıkarmak üzere filtrelerin otomatik olarak ayarlanması için öğrenilmiş parametreleri vardır. Her katmandan sonra daha fazla soyut bilgi için görüntüleri filtreleyen çoklu evrişimli katmanlar kullanılmaktadır. Havuzlama katmanı verilen girdinin uzaysal boyutu boyunca alt örnekleme gerçekleştirmektedir ve aktivasyon içindeki parametre sayısını daha da azaltmaktadır. Havuzlama katmanı ayrıca bellek tüketimini azaltır ve böylece evrişimli katmanların daha sık kullanılmasına izin vermektedir (LeCun ve ark. 1998; O'Shea ve Nash 2015).

#### 2.4.5.1.1.1. Konvolüsyonel Sinir Ağları (KSA) Mimarileri

KSA son zamanlarda büyük ölçekli görüntü ve video tanımda büyük bir başarı elde etmiştir. Bu konvolüsyonel sinir ağlarının etkili mimarileri aşağıdaki gibi listelenebilir (Coşkun ve ark. 2017).

**LeNet**, LeCun tarafından LeNet-5 olarak adlandırılan öncü bir çalışmadır. O zamanlar LeNet mimarisi esas olarak posta kodlarını, rakamları vb. okumak gibi karakter tanıma görevleri için kullanılıyordu. LeNet'in tanıtımıyla LeCun ve ark. ayrıca, rakam tanıma alanında standart ölçüt olarak bilinen MNIST veritabanını da tanıttı (LeCun ve ark. 1989).

**AlexNet**, KSA'ları bilgisayarlarda popüler hale getiren bir çalışmadır. 5 evrişimli katmandan ve ardından 3 tamamen bağlı katmandan oluşmaktadır. Alex Krizhevsky ve arkadaşları tarafından geliştirilmiştir (Krizhevsky ve ark. 2017).

**ZFNet**, Matthew Zeiler ve Rob Fergus tarafından geliştirildi. AlexNet'te mimari hiperparametreleri değiştirdi ve özellikle orta evrişimli katmanların boyutunu genişleterek ve ilk katmandaki adım ve filtre boyutunu küçülttü (Zeiler ve Fergus 2014).

**VGGNet**, AlexNet'e göre daha fazla gelişmiş olup toplamda 19 katmana sahiptir. Anafikri, ağın derinliğinin veya katman sayısının daha iyi performans için kritik bir bileşen olduğunu göstermekti. VGGNet, ImageNet veri kümesinde olağanüstü bir doğruluk elde etmesine rağmen, en küçük boyutlu grafik işlem birimlerine bile yerleştirilmesi, hem bellek hem de zaman açısından büyük hesaplama gereksinimleri nedeniyle bir sorundur (Simonyan ve Zisserman 2014).

**GoogleNet**, Szegedy ve arkadaşları tarafından icat edildi. Ana katkısı, ağdaki parametre sayısını önemli ölçüde azaltan bir başlangıç modülünün geliştirmesiydi. (Szegedy ve ark. 2015).

#### **2.4.5.1.2. Tekrarlayan Sinir Ağları ( Recurrent Neural Network - RNN)**

Tekrarlayan sinir ağları, sıralı verileri işlemek için kullanılan bir sinir ağları ailesidir. Ses tanıma, dil modelleme, çeviri, resim yazısı gibi çeşitli alanlarda büyük vaatler vermiş popüler modellerdir. Bu sinir ağlarına tekrarlayan denir çünkü bir dizinin her ögesi için aynı görevi yerine getirirler ve çıktı önceki hesaplamalara bağlıdır. Başka bir deyişle, o ana kadar hesaplanan bilgileri saklayan bir hafızaları vardır (Graves ve ark. 2008; Mikolov ve ark. 2010; Graves ve ark. 2013; Zhang ve ark. 2016).

#### **2.4.5.1.3. Kısıtlı Boltzmann Makineleri (Restricted Boltzman Machine - RBM)**

İlk tanıtıldıkları zamanlara kıyasla, hesaplama gücündeki artış ve görüntü sınıflandırması, doku sentezi, tıbbi görüntü işleme gibi birçok alanda yeni öğrenme algoritmalarının geliştirilmesi nedeniyle Kısıtlı Boltzmann Makineleri daha kompleks sorunlara uygulanabilir (Hinton ve Salakhutdinov 2006; Tang ve ark. 2012).

Kısıtlı Boltzmann Makineleri yapısal olarak görünür katman (giriş katmanı) ve gizli katman olan sadece iki katmana sahip sığ bir sinir ağıdır. Girdiyi yeniden yapılandırarak verilerdeki kalıpları otomatik olarak bulabilen bir yöntemdir. Kısıtlı Boltzmann Makineleri, her katmandaki nöronların aralarında hiçbir bağlantısı olmaması ve diğer katmandaki diğer tüm nöronlara bağlı olması nedeniyle sınırlı kabul edilir (Hinton 2002).

#### **2.4.5.2. Derin Öğrenme ile Nesne Tespiti**


Derin öğrenme tekniklerinin hızla gelişmesiyle birlikte, nesne tespiti daha önemli hale gelmiştir. Nesne tespiti video analizi ve görüntü anlama ile yakın ilişkisi nedeniyle de son yıllarda araştırmacıların büyük ilgisini çekmiştir. Nesne tespitinin temeli, tespit edilen nesneleri lokalize etmek ve kategorize etmek için dikkettiren sınırlayıcı kutular kullanmaktır. Nesne tespitinde tam bir görüntü anlayışı elde etmek için, yalnızca farklı görüntüleri sınıflandırmaya odaklanmakla kalmamalı, aynı

zamanda her görüntüde yer alan nesnelerin kavramlarını ve konumlarını kesin olarak tahmin etmeye çalışılmalıdır (Xiao ve ark. 2020).

Nesne tespiti; bilimsel araştırma ve pratik endüstriyel üretimde yüz algılama (Taigman ve ark. 2014), metin algılama (Huang ve ark. 2014) ,yaya algılama (Ouyang ve Wang 2013), logo algılama (Hoi ve ark. 2015), video algılama (Kang ve ark. 2016), tıbbi görüntü algılama (Litjens ve ark. 2017) çalışmalarında kullanılmıştır.

Nesne tespitinin, nesne sınıflandırması, semantik segmentasyon ve örnek segmentasyon ile bazı ilişkileri vardır.

- a) Nesne sınıflandırması, görüntüdeki nesnelerin kategorisini tanımlamalıdır.
- b) Nesne tespitinin yalnızca nesnelerin kategorisini tanımlaması gerekmez, aynı zamanda dikdörtgen sınırlayıcı kutularla nesnelerin yerini belirlemesi gerekir.
- c) Semantik segmentasyon yalnızca her bir pikselin kategorilerini tahmin etmesi gerekir ve nesne örneklerini ayırt etmesi gerekmez.
- d) Örnek segmentasyonu, hem her bir pikselin kategorilerini hem de nesne örneklerini tahmin etmelidir (Xiao ve ark. 2020).



**Resim 3:** Derin Öğrenme ile Nesne Tespiti a) Nesne sınıflandırması b) Nesne tespiti c) Semantik segmentasyon d) Örnek segmentasyon (Xiao ve ark. 2020)

Nesne tespiti kısmı kendisinden sonra gelen kısımların başarı oranıyla doğrudan ilişkili olduğu için en önemli aşamadır (Özbaysar ve Borandağ 2018).

#### 2.4.5.2.1. Nesne Tespit Algoritmaları

##### 2.4.5.2.1.1. Geleneksel Nesne Tespiti Algoritmaları

Hesaplama kaynaklarının, veri setlerinin ve temel teorilerin sınırlandırılması, son yıllarda derin sinir ağlarının geliştirilmesini ve uygulanmasını sınırlamıştır. Bu nedenle, geleneksel nesne tespiti algoritmaları hala popülerdir (LeCun ve ark. 2015).

Geleneksel nesne tespit algoritmaları daha uzun süredir var olmasına rağmen, eksiklikleri vardır. Birincisi, kayan pencere tabanlı bölge seçim stratejisi, yüksek hesaplama kompleksliğine ve yüksek pencere fazlalığına sahiptir. İkincisi, görüntülerin morfolojik çeşitliliği, aydınlatma değişikliklerinin çeşitliliği ve arka planın çeşitliliği, temel özelliklerin manuel olarak tasarlanmasını zorlaştırır (Girshick ve ark. 2014).

Geleneksel nesne tespit algoritmaları (Tan ve ark. 2021):

- Oxford-MKL
- DPM
- NLPR-HOGLBP
- Selective Search

#### 2.4.5.2.1.2. Derin Öğrenmeye Dayalı Nesne Tespit Algoritmaları

##### 2.4.5.2.1.2.1. İki Aşamalı Nesne Tespit Algoritmaları

- **RCNN (Region Based Convolutional Networks):** Birinci aşamada nesneye ait lokalizasyon önerileri çıkartmak, ikinci aşamada lokalizasyon önerilerine konvolüsyonel sinir ağı uygulamaktadır (Ren ve ark. 2015).
- **Fast RCNN:** Derin konvolüsyonel sinir ağları kullanmıştır. Geçmiş çalışmalardan faydalanmış ve bunun sonucunda nispeten daha hızlıdır. Verim de bu sayede artmıştır. RCNN' nin hız problemini elimine etmek amacıyla geliştirilmiştir (Girshick ve ark. 2015). Dezavantajı düşük hızda olan seçici bir arama algoritması olmasıdır (Shetty ve Jogi 2019).
- **Faster RCNN:** RCNN serisinin üçüncü seviyesidir. Faster RCNN'de seçici arama özelliği elimine edilmiştir. Doğru nesne

tespiti sağlarken önerilen bölgelerin sayısını azaltan bölgesel teklif ağı uygulanmaktadır (Shetty ve Jogi 2019).

- **Mask RCNN:** Sınırlayıcı kutu tanıma için mevcut dala paralel olarak nesne tahmini için bir dal ekleyerek Faster RCNN'yi genişletir. Mask RCNN'nin eğitilmesi kolaydır. Ayrıca, Mask RCNN'in genelleştirilmesi kolaydır, örneğin aynı çerçevede insan pozlarını tahmin etmemize izin verir. Örnek segmentasyonunda ve sınırlayıcı kutu nesne tespitinde en iyi sonuçları verir (He ve ark. 2017).

#### 2.4.5.2.1.2.2. Tek Aşamalı Nesne Tespiti

Tek aşamalı algılama algoritması, hızlı çıkarım hızı ve yüksek gerçek zamanlı performans avantajlarına sahiptir, ancak doğruluk, iki aşamalı nesne algılama algoritmasından biraz daha düşüktür (Yan ve ark. 2022).

- **OverFeat:** OverFeat, nesne sınıflandırmasını ve nesne lokalizasyonunu gerçekleştirmek için RCNN'nin sınıflandırmasını ve regresyonunu kullanır. RCNN ile karşılaştırıldığında, OverFeat hız açısından bariz avantajlara sahiptir, ancak doğruluk açısından yetersizdir (Harzallah ve ark. 2009).
- **YOLO:** YOLO 2015'te ilk olarak ortaya çıkmış ve zamanla yeni sürümleri geliştirilmiş ve gelişmeye devam eden temeline evrimsel sinir ağlarını alan bir nesne tespit algoritmasıdır (Jiang ve ark. 2022).
- **SSD:** RCNN serisi ve YOLO'nun hız ve doğruluk açısından kendi avantajları vardır. RCNN serisi, yüksek algılama doğruluğuna sahiptir, ancak hızı yavaştır. YOLO hızlı algılama hızına sahip

olmasına rağmen, nesnenin büyük boyutsal değişimle genelleme yeteneği ve küçük nesneler için algılama etkisi zayıftır (Liu ve ark. 2016).

#### 2.4.5.2.2. YOLO (You Only Look Once)

Son yıllarda oldukça popüler olan YOLO görüntü veya videoda nesne tespiti tek seferde hızla gerçekleştirebilmektedir. YOLO hızlıdır çünkü YOLO'nun nihai algılama sonucunu elde etmek için yalnızca girdi verilerini ağa koyması gerekir, böylece YOLO videonun zaman algılamasını da gerçekleştirebilir (Jiang ve ark. 2022).

YOLO, görüntüyü  $S \times S$  ızgaralarına böler ve her bir ızgara hücresi için B sınırlayıcı kutu ve C sınıfı olasılığı tahmin eder. Her sınırlayıcı kutu beş tahminden oluşur: w, h, x, y ve nesne güvenirliliği. w ve h değerleri, kutunun tüm görüntüye göre genişliğini ve yüksekliğini temsil eder. (x, y'nin değerleri), ızgara hücresinin sınırlarına göre kutunun merkez koordinatlarını temsil eder (Yan ve ark. 2022).



**Resim 4:** YOLO nesne tespiti akış şeması (Yan ve ark. 2022)

YOLO, genel bilgiyi kodlayabilmek ve arka planı nesne olarak algılama hatasını azaltabilmek için doğrudan küresel görüntüyü kullanır. YOLO, güçlü bir genelleme yeteneğine sahiptir çünkü YOLO, diğer alanlara aktarılmak üzere oldukça genelleştirilmiş özellikleri öğrenebilir. Hedef tespiti problemini bir gerileme problemine dönüştürür, ancak tespit doğruluğunun iyileştirilmesi gerekmektedir. YOLO'nun test sonuçları birbirine çok yakın, benzer ve grup halindeki cisimler için yetersizdir. Bu zayıf performansın nedeni, ızgaradaki yalnızca iki kutunun tahmin

edilmesi ve yalnızca aynı kategorideki yeni bir nesne sınıfına ait olmasıdır, bu nedenle anormal bir en boy oranı ve zayıf genelleme yeteneği gibi diğer koşullar ortaya çıkar. YOLO, birden fazla alt örnekleme katmanı kullanır ve ağdan öğrenilen hedef özellikler, algılama etkisinin iyileştirilebilmesi için kapsamlı değildir (Jamtsho ve ark. 2020).

## **YOLO v2**

YOLO tahmin doğruluğunu iyileştirmek için Redmon ve ark. 2017'de yeni bir YOLO v2 sürümü önermiştir (Redmon ve Farhadi 2017). Faster RCNN'nin mekanizmasına atıfta bulunarak, bağlantı kutularını elde etmek için ortalama kümeleme kullanılmıştır. Ek olarak, tahmin edilen kutular doğrudan tahmin ile yeniden eğitilmiştir. YOLO ile karşılaştırıldığında YOLO v2, nesne algılamanın doğruluğunu ve hızını büyük ölçüde artırmaktadır.

Bununla birlikte, genel bir nesne algılama modeli olarak YOLO v2, algılanacak çeşitli sınıfların olduğu ve insanlar, atlar ve bisikletler gibi sınıflar arasındaki farkların büyük olduğu durumlara uygulanabilir. Ancak, araç tespiti için farklılıklar genellikle lastikler, farlar vb. gibi yerel alanlardadır (Yan ve ark. 2022).

## **YOLO v3**

YOLO, iki nesne çok yakın olduğunda veya çok çeşitli en-boy oranları olduğunda iyi performans gösterememektedir; bu da çok sayıda yerelleştirme hatasına neden olmaktadır. Aynı zamanda zayıf koordinat doğruluğuna ve düşük hatırlamaya yol açmaktadır. Bu sorunu azaltmak ve hız ile doğruluğu daha iyi tutmak için YOLO v3 önerilmiştir. YOLO v3, karşılaştırılabilir performansla diğer birçok algılama yönteminden önemli ölçüde daha hızlı çalışmaktadır (Redmon ve Farhadi 2017).

## YOLO v4

YOLO v3 ile karşılaştırıldığında, YOLO v4, veri işlemede mozaik veri geliştirmeyi tanıtmıştır. Ek olarak, omurga, ağ eğitimi, etkinleştirme işlevi ve kayıp işlevi optimize edilmiştir; böylece YOLO v4 daha hızlı hale getirilmiştir ve bu gerçek zamanlı nesne algılama algoritmalarında doğruluk ve hız arasında en iyi dengeyi sağlamıştır (Bochkovskiy ve ark. 2020).

## YOLO v5

YOLO v5, tespit doğruluğu ve tespit hızını aynı anda geliştirmesi nedeniyle yoğun ilgi ve uygulama görmüştür. Küçük nesnelere karşı hassas değildir ve küçük nesneler bu yüzden kolayca gözden kaçabilmektedir. YOLO v5'in küçük nesneler için zayıf tespit performansının ana nedeni, küçük nesnelerin görsel özelliklerinin belirgin olmaması ve özellik bilgisi ile konum bilgisinin kademeli olarak kaybolmasıdır. İkincil nedeni, küçük nesneler, özellikle boyutu  $32 \times 32$  pikselden küçük olanların arka planla karışması kolaydır. Özellik çıkarıldıktan sonra, özellik haritasındaki bir piksel kendisini ve çevresindeki arka plan gürültüsünü kaplar ve bu da algılama zorluğunu daha da artırır (Yan ve ark. 2022).

YOLO v5, veri yükleyici aracılığıyla her bir eğitim verisi grubunu sağlar ve aynı anda eğitim verilerini geliştirir. Veri yükleyici, üç tür veri geliştirme gerçekleştirir: ölçekleme, renk alanı ayarı ve mozaik geliştirme. Veriler, mozaik geliştirmenin gerçekten de model eğitimindeki en zahmetli küçük nesne problemini etkili bir şekilde çözebileceğini kanıtlıyor; yani, algılanan küçük nesne, büyük nesne kadar doğru değildir (Yan ve ark. 2022).

## YOLO v6

YOLO v6 Haziran 2022'de Meituan tarafından geliştirilmiştir. YOLO v6 modeli 295 katmana sahiptir. YOLO v6 modeli, üretim uygulamalarında kullanılabilen istikrarlı ve başarılı tek aşamalı bir nesne tespiti algoritmasıdır. YOLO v6, COCO etiket yapısını kullanarak yolov6n.pt, yolov6s.pt ve yolo6t.pt gibi farklı ağırlıklar kullanarak nesnelerin keşfini gerçekleştirir (Yung ve ark. 2022).

## YOLO v7

YOLO v7, Chien-Yao Wang, Alexey Bochkovskiy ve Hong-Yuan Mark Liao tarafından, bir özelliğin katmanlar arasında geri yayılması için gereken mesafenin yanı sıra katmanları tutmak için gereken belleği hatırlayarak oluşturuldu. Özellik ne kadar küçük olursa, model o kadar güçlü bir şekilde öğrenir. Seçilen son katman kombinasyonu, ELAN hesaplama biriminin üst düzey bir yorumu olan genişletilmiş verimli katman toplama ağı (E-ELAN) idi. Katmanları birbirine bağlarken iyi performans elde etmek için modelin derinliği ve genişliği ölçülmüştür. Bu algoritma, farklı boyutlar için düzenleme yaparken yapıyı en iyi şekilde tutar ve YOLO v7 modeli, aynı çıkarım hızlarında önceki sürümlerden daha doğru bir şekilde dikdörtgen kutular çizer (Wang ve ark. 2022; Yung ve ark. 2022).

## YOLO v8

YOLO v8, nesne tespit, görüntü sınıflandırma ve örnek bölümlendirme görevleri için kullanılabilen en yeni YOLO modelidir. YOLOv8, etkili ve sektöre yön veren YOLOv5 modelini de yaratan Ultralytics tarafından geliştirilmiştir. YOLOv8, YOLOv5'e göre çok sayıda mimari ve geliştirici deneyimi değişikliği ve iyileştirmesi içerir (Solawetz ve Francesco 2023). Önceki YOLO sürümlerinden yararlanan YOLO v8 modeli, eğitim modelleri için birleşik bir çerçeve sağlarken daha hızlı ve daha doğrudur (Rath 2023).

Günümüzde birçok derin öğrenme ile çürük tespiti çalışmaları bulunmaktadır (Cantu ve ark. 2020; Mao ve ark. 2021; Bayrakdar ve ark. 2022; Chen ve ark. 2022; Estai ve ark. 2022; Panyarak ve ark. 2023). Ancak bitewing radyograflar üzerinde derin öğrenme ile hem okluzal hem sekonder hem de interproksimal çürükleri tespit edip interproksimal çürükleri derinliğine göre sınıflandıran (d1-d2-d3) bilinen bir çalışma bulunmamaktadır. Yapılan bu tez çalışmasında yapay zekâ algoritmalarından YOLO'nun YOLO v8 mimarisini kullanarak bitewing radyograflar üzerinde sekonder, okluzal ve interproksimal (d1-d2-d3) çürükleri tespit edebilmesi ve klinik işleyişte diş hekiminin işlerini kolaylaştırmak amaçlanmıştır. Çalışmamızın hipotezi 'Derin öğrenme algoritmaları bitewing radyograflarda çürükleri tespit edebilir ve sınıflandırabilir' olarak belirlenmiştir.

### 3. GEREÇ VE YÖNTEM

Bu çalışma; Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Kliniği'nde, Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurulu tarafından 30.06.2022 tarih ve 12-94 sayılı izni alınarak gerçekleştirilmiştir.

#### 3.1. Gereç

##### 3.1.1. Görüntülerin Toplanması

Bu çalışmada 2014-2021 yılları arasında Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi kliniğine farklı tanısal sebeplerle başvuran hastaların arşivde yer alan bitewing radyografları kullanılmıştır. Bitewing radyograflar çift taraflı olarak alınmıştır.

Çalışmada kullanılan bütün bitewing radyograflar Morita Veraview X Type R İntraoral Dijital Görüntüleme Cihazı (J. Morita Corp., Kyoto, Japan) cihazı kullanılarak elde edilmiştir. 2 numaralı fosfor plaklar çekimde kullanılmıştır. Bitewing radyograflar elde edilirken üretici firmanın tavsiye ettiği çekim protokolleri (70 kVp, 7 mA, 0.25 sn) uygulanmıştır. Çekilen bitewing radyograflar Soredex (Digora Optime, Finland) marka görüntü tarayıcı sistemi ile kayıt altına alınmıştır. Bitewing görüntüler Windows 10 Professional işletim sistemli 4.00 Gb RAM'a sahip, 1366x768 piksel çözünürlüğünde 15.6 inç'lik panel renkli ekranı (Toshiba Satellite C55-A-1PU) olan 2.50GHz Intel(R) Core(TM) i5-4200M CPU PC'de incelenmiştir.

#### **Araştırmaya Dâhil Etme Kriterleri**

- Tanısal açıdan uygun görüntü kalitesine sahip
- Alt-üst dişlerin (premolar-molar-kanin) kron ve 1/3 kök anatomisinin incelenebildiği,

- Morita Veraview X Type R İnteraoral Dijital Görüntüleme Cihazı ile çekilen ve Soredex (Digora Optime, Finland) cihazı kullanılarak taranan bitewing görüntüler çalışmaya dâhil edilmiştir.

### **Dışlama Kriterleri**

- Tanısal açıdan uygun görüntü kalitesine sahip olmayan, artefakt (distorsiyon, gürültü, çift ışınlama, ters yerleştirilmiş reseptör, konkat, hareket artefaktı) bitewing radyograflar,
- Horizontal açılama hataları sebebiyle süperpozisyonların olduğu bitewing radyograflar,
- Morita Veraview X Type R İnteraoral Dijital Görüntüleme Cihazı ile çekilmeyen ve Soredex (Digora Optime, Finland) cihazı dışında bir cihazla taranan radyograflar çalışma dışında tutulmuştur.


Belirtilen kriterlere uygun toplam 860 bitewing radyograf toplanmıştır.

## **3.2. Yöntem**

### **3.2.1. Görüntü Ön İşleme**

- Çalışmada elde edilen 860 bitewing radyografların satır ve sütun boyutları birbirinden farklıdır.
- Derin öğrenme algoritmalarının standart işlemler gerçekleştirebilmesi için görüntüler \*.tiff formatından \*.jpg formatına dönüştürülmüştür.
- Elde edilen bitewing radyografların satır ve sütun boyutları 1324x1014 ile 612x514 piksel arasında farklılık göstermektedir.
- Algoritmaların optimum performans göstermesi için tüm verilerin standardize olması gerekmektedir. Bu sebeple satır ve sütun boyutları aynı olacak şekilde resize edilmelidir.
- Tüm bitewing radyograflar 512x400 piksel boyutuna bilinear interpolasyon yöntemi kullanılarak resize edilmiştir.

- Veri sayısını arttırmak için 860 görüntü 3 farklı yönde döndürülerek 3440 radyografa çıkarılmıştır. **Resim 5a**'da orijinal bitewing radyograf, **Resim 5b**'de orijinal radyografin y ekseninde 180 derece döndürülmesi (yatay döndürme), **Resim 5c**'de orijinal radyografin x ekseninde 180 derece döndürülmesi (dikey döndürme), **Resim 5d**'de orijinal radyografin x ekseninde 180 derece döndürülmesinin ardından y ekseninde 180 derece döndürülerek (dikey + yatay döndürme) veri çoğaltması gösterilmektedir. Bu işlem görüntü içeriğini değiştirmemekte, sadece görüntüye bakılan açıyı değiştirdiği için farklı patern oluşturmaktadır.




**Resim 5:** (a) Orijinal bitewing radyograf (b) Orijinal radyografin y ekseninde 180 derece döndürülmesi (yatay döndürme) (c) Orijinal radyografin x ekseninde 180 derece döndürülmesi (dikey döndürme) (d) orijinal radyografin x ekseninde 180 derece döndürülmesinin ardından y ekseninde 180 derece döndürülmesi (dikey+yatay döndürme)

### 3.2.2. Görüntülere Sınırlayıcı Kutuların Çizilmesi ve Etiketlenmesi

- Görüntülerin etiketlenmesi işlemi 2 yıllık oral radyoloji deneyimi olan Ağız, Diş ve Çene Radyolojisi uzmanlık öğrencisi ve 12 yıllık deneyimli bir radyolog tarafından yapılmıştır.
- Gözlemci içi ve gözlemciler arası uyumun değerlendirilmesi için görüntülerin %10'u iki radyolog tarafından etiketlenmiştir. Gözlemci içi ve gözlemciler arası uyuma ilişkin Kappa değerleri 0.95 ve 0.91'tir. Landis ve Koch'a (1977) göre 0'dan küçük değerler uyumsuzluğu, 0.01-0.20 zayıf uyumu, 0.21- 0.40 orta düzeyde uyumu, 0.41-0.60 kabul edilebilir uyumu, 0.61-0.80 iyi uyumu ve 0.81-1.00 ise mükemmel uyumu göstermektedir (Landis ve Koch 1977).
- Görüntü boyutları eşitlenen bitewing radyograflarda okluzal, interproksimal (d1-d2-d3) ve sekonder çürük etiketi yapılmıştır.
- Etiketler yapılırken çürüğün komşu olduğu sağlıklı diş dokusunun küçük bir alanı, çürüğün bulunduğu dokuyla sınırı ve çürük alanı bütünüyle etikete dâhil edilmiştir.
- Okluzal çürük değerlendirildiğinde okluzal yüzeyden çürüğün sınırları ve çürüğün komşu olduğu sağlıklı dentin dokusunun küçük bir alanına kadar uzanan alan etikete dâhil edilmiştir.
- İnterproksimal çürükler değerlendirildiğinde interproksimal yüzeyden çürüğün sınırları ve çürüğün komşu olduğu sağlıklı diş dokusunun küçük bir alanına kadar uzanan alan etikete dâhil edilmiştir.
- Sekonder çürük değerlendirildiğinde çürük sınırları, çürüğün bulunduğu sağlıklı dokunun bir kısmı ve restoratif materyalin çürük ile komşu küçük bir alanı etikete dâhil edilmiştir.
- Sabit protetik kron tedavilerinin uygulandığı durumlar da sekonder çürük açısından değerlendirilmiştir. Çürük varlığı durumunda çürüğün tespit edilebilen sınırları ve protetik materyalin küçük bir alanı etikete dâhil edilmiştir.
- Kron yapısının çeşitli sebeplerle total olarak kaybedildiği durumlarda etiketleme yapılmamıştır.
- Bitewing radyografin diş dokusunun mezial veya distal kron ve kök 1/3'ünün tamamının görüntülenemediği durumlarda o dişte etiketleme yapılmamıştır.

- Etiketleme işlemi browser tabanlı ve açık erişimli <https://www.makesense.ai/> internet adresi üzerinden gerçekleştirilmiştir (**Resim 6**).




**Resim 6:** makesense.ai sitesinin ana sayfa ekran görüntüsü


Etiketleme işleminde beş çeşit etiket kullanılmıştır: Okluzal çürük varlığında ‘**okluzal çürük**’; interproksimal çürük varlığında Lian sınıflamasına göre mine veya dentinin dış üçte birlik bölgesinde radyolüsensi ‘**d1**’, dentinin orta 1/3’üne uzanan radyolüsensi ‘**d2**’ ve görünür pulpa tutulumu olan veya olmayan derin radyolüsensi ‘**d3**’; sekonder çürük varlığında ise ‘**sekonder çürük**’ olarak etiketlenmiştir (Lian ve ark. 2021).

- Etiketleme işleminde radyolog tecrübesine göre ilgili bölgelere sınırlayıcı kutular çizilir.
- Programda çizilen sınırlayıcı kutuların görüntü üzerindeki koordinat değerleri \*.txt dosyasına kaydedilir.
- Her bir görüntünün koordinat değerlerine göre oluşturulan YOLO formatındaki \*.txt dosyaları bilgisayara indirilmiştir.
- **Resim 6**’da makesense sitesinin ana sayfası, **Resim 7**’de makesense.ai sitesinde etiketlemenin yapıldığı ekran (sekonder çürük, okluzal çürük, d3 ve d2

interproksimal çürüklerinin etiketlendiği bir bitewing radyograf), **Resim 8**'de d1 ve d2 interproksimal çürüklerinin etiketlendiği bir bitewing radyografın ekran görüntüsü verilmiştir.



**Resim 7:** makesense.ai sitesinde etiketlemenin yapıldığı ekran (**Sekonder çürük, oklüzal çürük, d3 ve d2** interproksimal çürüklerinin etiketlendiği bir bitewing radyograf)



**Resim 8:** makesense.ai sitesinde etiketlemenin yapıldığı ekran (**d1 ve d2** interproksimal çürüklerinin etiketlendiği bir bitewing radyograf)

### 3.2.3. Veri Setlerinin Oluşturulması

- Eğitim ve test işlemi için radyograflar rastgele 2752 eğitim ( $\cong\%80$ ), 344 validasyon ( $\cong\%10$ ), 344 test ( $\cong\%10$ ) olarak bölünmüştür.
- YOLOv8 eğitiminin gerçekleştirilmesi için “images” ve “labels” isimli iki klasör oluşturulmuştur.
- Radyograflar “images” klasörü içerisinde oluşturulan test, train, val klasörlerine yukarıda belirtilen oranlara göre ayrı ayrı kaydedilmiş, radyograflara denk gelen etiketler “labels” klasörü içerisindeki test, train klasörlerine kaydedilmiştir.
- Test görüntüleri model eğitimi tamamlandıktan sonra sistemin hiç görmediği veriler olacağı için etiket bilgilerinin klasöre kaydedilmesine gerek yoktur.
- Veri setleri oluşturulduktan sonra tümü \*.rar dosyası şekline getirilerek Google COLAB platformuna kaydedilmiştir. COLAB platformu Google firması tarafından kullanıcıların derin öğrenme mimarileri gibi Python kodlarını çalıştırabildikleri Linux ve bulut tabanlı sanal bilgisayarlardır.
- Çalışmada eğitim ve test işlemlerinin daha sağlıklı ilerlemesi için COLAB Pro versiyonu satın alınarak işlemler 32 GB RAM e sahip NVIDIA Tesla T4 GPU donanımı üzerinden gerçekleştirilmiştir.

### 3.2.4. YOLO v8 ile Model Eğitimi

YOLO ailesinin son sürümü olan YOLO v8 modeli kullanıcılara tespit, segmentasyon ve sınıflandırma için eğitilmiş hazır modeller sunmaktadır. Hazır modeller indirilerek araştırmacılar gerekli ayarlamalardan sonra kendi veri setleri üzerinde eğitim işlemi gerçekleştirebilmektedir (Transfer Learning). Bu tez çalışmasında, çürüklerin tespit ve lokalizasyon işlemi yapılacağı için YOLO v8 modelinin tespit modelleri incelenmiştir. YOLO v8 8n, 8s, 8m, 8l ve 8x olmak üzere farklı tespit modelleri sunmaktadır. Bu modellerin çıktı olarak işlevleri aynı ancak model büyüklüğü, hızları ve hesaplanan parametre değerleri 8x modeline doğru ilerledikçe artmaktadır. Model büyüklüğünün artması daha fazla parametre hesabı getirdiğinden dolayı ihtiyaç duyulan donanım gereksiniminin büyümesine neden olmaktadır. Donanımın yetersiz gelmesi durumunda sistem “**Out of**

**Memory**” hatası vermektedir. Bu aşamalar dikkate alınarak YOLO v8 algoritmasının boyut ve parametre hesabı olarak orta büyüklükte olan 8m sürümü bu çalışmada kullanılmıştır. YOLO v8 modeli ve 8m sürümü “<https://github.com/ultralytics/ultralytics>” sitesi üzerinde COLAB platformuna indirilmiştir. Gerekli etiket ve izin ayarlamalarından sonra model parametrelerinden mini-batch size 4, öğrenme oranı 0.01, optimizasyon algoritması Stochastic Gradient Descent ve epoch sayısı 600 girilerek modelin eğitim süreci başlatılmıştır. Diğer hiper parametreler varsayılan olarak bırakılmıştır.

### 3.2.5. Performans Kriterleri

Performans kriterleri eğitim ve test olmak üzere iki aşamada değerlendirilmiştir.

- Eğitim aşamasında validasyon verileri ile eğitimin performans değerleri **kesinlik (precision), duyarlılık (recall), F1 skor ve mAP** metrikleri ile hesaplanmaktadır.
- Test aşamasında **kesinlik, duyarlılık, F1 skor ve inference time** metrikleri ile sonuçlar değerlendirilmiştir.

Bu metriklerin hesaplanmasının temelinde **IoU (Intersection over Union)** parametresi yatmaktadır. Algoritma tahmin sürecinde ilgili bölgeye bir sınırlayıcı kutu çizmektedir. Çizilen kutu ile radyoloğun altın standart olarak belirlediği sınırlayıcı kutunun belli oranda örtüşmesi algoritma performansını doğrudan etkilemektedir. IoU değeri algoritmanın çizdiği kutu (**A**) ile radyoloğun çizdiği sınırlayıcı kutunun (**B**) kesişim alanının (intersection), iki kutunun birleşimine (Union) oranıdır (**Denklemler 1**). IoU sonucunun en az %50 olması tahmin sürecinin kabul edilebilir sınırıdır. IoU metriği dikkate alınarak, kesinlik ve duyarlılık değerlerinin hesaplanması için **Doğru Pozitif (DP), Yanlış Pozitif (YP), Yanlış Negatif (YN)** sayıları hesaplanmaktadır.

- **Doğru Pozitif (DP):** Doğru tespit. Radyolog çürük tahmini ile sistemin çürük tahmin ettiği bölge ve sınıfların aynı olduğu nesne sayısı
- **Yanlış Pozitif (YP):** Yanlış Tespit. Radyolog çürük tahminine göre sistemin tahminde yanlış bulduğu nesne sayısı
- **Yanlış Negatif (YN):** Bulunamayan gerçek çürük bölgesi. Radyolog tahminin olduğu ancak sistemin hiçbir bölge bulamadığı nesne sayısı
- **Doğru Negatif (DN):** Radyolog tahmini olmadığı halde sistemin de çürük bölge olarak kabul etmediği nesne sayısı. (Nesne tespit algoritmalarının performans değerlendirilmelerinde kullanılmaz).

Bu değerlerden yola çıkarak kesinlik formülü **Denklem 2**'de, duyarlılık formülü **Denklem 3**'de, F1 Skor formülü **Denklem 4**'de verilmiştir.

- **Kesinlik:** Kesinlik bilgisi doğru çürük tespit edilen bölgelerin tüm çürük tespit edilen bölgelere oranını vermektedir. Algoritmanın tespit ettiği çürüklerde ne kadarının doğru olduğunu ve algoritmanın ne kadar iyi iş yaptığını göstermektedir.
- **Duyarlılık:** Duyarlılık bilgisi doğru tespit edilen çürük bölgelerinin tüm tespit edilmesi gereken bölgelere oranıdır. Algoritmanın tüm veri setinde doğru bölgeleri ne kadar iyi bulduğunu ölçen bir metriktir.
- **F1 Skor:** F1 skor bilgisi kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır.

Denklem 1

$$IoU = \left| \frac{A \cap B}{A \cup B} \right|$$

Denklem 2

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

Denklem 3

$$Duyarlilik = \frac{DP}{DP + YN} = \frac{DP}{TümTespitEdilmesiGerekenler}$$

Denklem 4

$$F1-Skor = 2 * \frac{Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik}$$

Eğitim ve validasyon sürecinde kesinlik ve duyarlılık değerleri YOLOv8 tarafından otomatik bir şekilde hesaplanmaktadır. Test sürecinin değerlerinin hesaplanması için öncelikle eğitim sonucu elde edilen ağırlıklar kullanılarak test görüntüleri üzerinde çürüklerin lokalizasyonu ve sınıf bilgileri otomatik olarak tespit edilmiştir. Uzman radyologların bu görüntüleri değerlendirmesi ile duyarlılık, kesinlik ve F1-skor değerleri hesaplanmıştır. Eğitim süreci için bir diğer metrik **mAP (mean Average Precision)** değeridir. Bu değer her sınıf için **ortalama hassasiyet (average precision-AP)** değeri belirlendikten sonra hesaplanır. Validasyon verisindeki her bir bitewing görüntüsünde elde edilen tespitler için ayrı ayrı hassasiyet ve kesinlik değerleri yüzde olarak hesaplanır. Bu değerler bir grafiğe **yazılarak kesinlik-hassasiyet (precision-recall)** grafiği elde edilir. Her bir sınıf için çizilen grafikte eğri altında kalan alan o sınıfın AP değerini vermektedir. mAP ise tüm sınıflar için elde edilen AP değerlerinin ortalamasıdır. Her bir sınıf için **AP değeri** hesabı **Denklem 5**'de, tüm sınıflar için **mAP** hesabı **Denklem 6**'da verilmiştir. mAP.5 değeri IoU'nun %50 olduğu durumdaki performansını, mAP.5 : .95 ise IoU eşiğinin %50 den %95'e adım büyüklüğü 0.05 olacak şekilde yukarıda belirtildiği gibi tek tek hesaplanarak ortalama alınmasını ifade etmektedir (k=Sınıf Bilgisi) (Padilla ve ark. 2020; Li ve ark. 2022; Roy ve ark. 2022).

Denklem 5


$$AP_k = \int_0^1 P_k(R_k) dR_k$$

Denklem 6

$$mAP = \frac{1}{k} \sum_{i=1}^k AP_i$$

Test sürecindeki bir diğer performans kriteri **sonuç çıkarma süresidir (inference time)**. Bu süre ağırlıkları elde edilen yapay zekânın test verilerini ne kadar sürede cevapladığının bir ölçüsüdür.

### 3.2.6. Klinik İçin Grafikselle Kullanıcı Arayüz Tasarımı



Resim 9: YOLOv8 Bitewing Radyograflarda Çürük Tespiti Arayüz Tasarımı

Eğitim sonucu elde edilen YOLO v8 ağırlıkları ile klinikte otomatik bitewing görüntülerinin analizi için “Decay AI” isimli bir arayüz tasarlanmıştır. Grafik kullanıcı arayüz için Python programının PYQT5 kütüphanesi kullanılmıştır. Geliştirilen programda yapay zekâ ağırlık dosyası arka plana gömülerek diş hekiminin tek tuşla

çürük lokalizasyonlarını ve türlerini görebileceği bir platform oluşturulmuştur. “Select Bitewing” tuşu ile işlenmek istenen bitewing görüntüsü seçilir, “Process Bitewing” tuşu ile çürüklerin otomatik lokalizasyonları ve türleri belirlenir. **Resim 9**’da “Decay AI” isimli programın kullanıcı arayüzü gösterilmektedir.


## 4. BULGULAR

### 4.1. Eğitim Sonuçları


COLAB ortamında gerçekleştirilen eğitim süreci 5.206 saat sürmüş, 146 epoch ta tamamlanmıştır. YOLOv8, eğitim sürecinde epochlarda anlamlı değişimler görülmediği zaman eğitim işleminde erken durdurma (early stopping) uygulamaktadır. Bundan dolayı parametre olarak girilen 600 epoch tamamlanmadan eğitim işlemi 146 epoch ta sonlandırılmıştır. Eğitim işlemi sonucunda 50 MB boyuta sahip “last.pt” isimli bir ağırlık dosyası elde edilmiştir. Bu dosya çürük çeşitlerini otomatik tespit etmek için elde edilen yapay zekâ dosyasıdır. **Tablo 4**’ de eğitim ve validasyon işlemi sonucu elde edilen performans sonuçları verilmiştir. **Şekil 7**’de epoch ilerleyişine göre performans kriterlerinin grafiksel gösterimleri verilmiştir. **Şekil 8**’de precision-recall eğrisi ve performans sonuçlarını gösteren sınıflara göre grafiksel gösterimi verilmiştir.

**Tablo 4:** Eğitim ve validasyon sonucu elde edilen performans sonuçları

| Sınıf         | Bitewing | Bölge | Kesinlik | Duyarlılık | F1-skor | mAP.5 | mAP.5:0.95 |
|---------------|----------|-------|----------|------------|---------|-------|------------|
| S             | 344      | 85    | 0.964    | 0.956      | 0.960   | 0.96  | 0.425      |
| O             | 344      | 49    | 0.995    | 0.939      | 0.966   | 0.965 | 0.477      |
| D1            | 344      | 148   | 0.965    | 0.959      | 0.962   | 0.972 | 0.409      |
| D2            | 344      | 332   | 0.970    | 0.965      | 0.967   | 0.971 | 0.473      |
| D3            | 344      | 41    | 0.904    | 1.000      | 0.950   | 0.958 | 0.667      |
| <b>Toplam</b> | 344      | 655   | 0.960    | 0.964      | 0.962   | 0.965 | 0.490      |



Şekil 7: Epoch ilerleyişine göre performans kriterlerinin grafiksel gösterimi



Şekil 8: Sınıflara göre precision-recall grafiği ve performans sonuçları


#### 4.2. Test Sonuçları

344 bitewing test görüntüleri eğitim sonucu elde edilen last.pt dosyasına verilerek çürüklerin lokalizasyonu ve sınıf bilgileri görüntüler üzerinde sınırlayıcı kutular ile otomatik belirlenmiştir. Aşırı tespiti engellemek için güven skoru (confidence skor) 0.25 altında olanlar maksimum olmayanı bastırma tekniği ile bastırılmıştır. Böylece aynı bölgeyi ifade eden birden fazla sınırlayıcı kutunun ortaya çıkması önlenmiştir.

Test görüntülerinde radyolog ile aynı tespiti yapılması DP, radyoloğa göre yanlış tespiti yapılması YP, radyoloğun semptom olarak belirlediği bölgede yapay zekânın herhangi bir bulgu ortaya koyamaması YN olarak değerlendirilmiştir. DN değeri performans hesaplama kriterlerinde dikkate alınmamaktadır. Test görüntülerine ait karmaşıklık matrisi oluşturularak kesinlik, duyarlılık, F1-skor değerleri hesaplanmıştır. **Resim 10**'da 8 adet bitewing görüntüsü üzerinde çürük bölgelerinin lokalizasyon ve sınıf bilgileri, **Tablo 5**'de test görüntüleri için oluşturulan karmaşıklık matrisi, **Tablo 6**'da FN, FP, FN değerleri ve kesinlik, duyarlılık, F1-skor değerleri verilmiştir.

**Tablo 5:** Karmaşıklık Matrisi

| Oral Radyolog | Sınıf | S   | O  | D1  | D2  | D3 | YN |
|---------------|-------|-----|----|-----|-----|----|----|
|               | S     | 104 | 1  | 0   | 0   | 0  | 7  |
|               | O     | 0   | 54 | 0   | 0   | 0  | 6  |
|               | D1    | 0   | 0  | 218 | 0   | 0  | 20 |
|               | D2    | 0   | 0  | 8   | 315 | 1  | 21 |
|               | D3    | 0   | 0  | 0   | 7   | 46 | 0  |
| YOLOv8 Tahmin |       |     |    |     |     |    |    |



**Resim 10:** 8 adet test görüntüsü üzerinde çürüklerin otomatik tespiti ve sınıf bilgileri

**Tablo 6:** Test Verileri DP, YP, YN sayıları ve performans kriterleri

|                 | DP  | YP | YN | Kesinlik | Duyarlılık | F1 Skor |
|-----------------|-----|----|----|----------|------------|---------|
| <b>Sekonder</b> | 104 | 1  | 7  | 0.990    | 0.937      | 0.963   |
| <b>Okluzal</b>  | 54  | 0  | 6  | 1.000    | 0.900      | 0.947   |
| <b>D1</b>       | 218 | 0  | 20 | 1.000    | 0.916      | 0.956   |
| <b>D2</b>       | 315 | 9  | 21 | 0.972    | 0.938      | 0.955   |
| <b>D3</b>       | 46  | 7  | 0  | 0.868    | 1.000      | 0.929   |
| <b>Toplam</b>   | 737 | 17 | 54 | 0.977    | 0.932      | 0.954   |

Bitewing radyograflarda okluzal, sekonder ve interproksimal çürüklerin YOLOv8 ile otomatik tespitinde hem eğitim aşamasında hem test aşamasında başarılı sonuçlar elde edilmiştir.

- **Tablo 4'**de verilen eğitim ve validasyon sonuçlarında ortalama kesinlik 0.960, duyarlılık 0.964, F1 skor 0.962, mAP.5 0.965, mAP .5:0.95 0.490 olarak elde edilmiştir. Değerlerin %100'e yakın olması eğitim sürecinin başarılı olduğunu göstermektedir. mAP 0.5:0.95 değeri COCO metriği olarak başarılıdır.
- **Şekil 7'**de epoch ilerleyişine performans metriklerinin hızlı bir şekilde 1 değerine doğru ilerlemesi, kayıp fonksiyonlarına göre loss değerlerin 0 değerine yaklaşması başarılı bir eğitim sürecinde beklenen ve önerilen grafiksel davranışlardır.
- **Şekil 8'**de her bir sınıfın AP değerlerine göre ve tüm sınıfların ortalama mAP değerlerine göre eğitim sürecinin kesinlik-duyarlılık açısından grafiksel davranışı görülmektedir. Sekonder, okluzal ve interproksimal çürüklerin %50 IoU eşik değerine göre AP değerlerinin 0.95 üzeri olması ve sınıfların ortalama mAP değerinin 0.965 elde edilmesi eğitimde tespit sürecinin başarılı olduğunu göstermektedir. AP ve mAP sonuçları ne kadar 1'e yakınsa, eğitimde tespit süreci o kadar iyidir. mAP değeri ilgilenen çürük bölgeleri için algoritmanın ne kadar iyi olduğunu ve yanlış pozitif değerlerden ne kadar iyi kaçındığının bir göstergesidir.

- Eğitim süreci sonucu elde edilen yapay zekâ ağırlık dosyaları ile sistemin hiç görmediği veriler test edilmiştir. Test verilerinin karmaşıklık matrisi **Tablo 5**'de, DP, YP, YN ve performans kriterleri **Tablo 6**'de verilmiştir. Sekonder, okluzal ve interproksimal çürüklerin ortalama kesinlik değeri 0.977, ortalama duyarlılık değeri 0.932, ortalama F1-skor değeri 0.954 olarak elde edilmiştir. Değerlerin 0.90 üzeri olması test sürecinin oldukça başarılı olduğunu göstermektedir. Sekonder çürüklerin 104 adedi doğru, 1 adedi okluzal olarak tespit edilmiş, 7 adedi algoritma tarafından bulunamamıştır. Okluzal çürüklerin 54 adedi doğru tespit edilmiş, 6 adedi algoritma tarafından bulunamamıştır. İnterproksimal çürüklerin 579 adedi doğru, 16 adedi yanlış tespit edilmiş, 41 adedi algoritma tarafından bulunamamıştır.
- YOLO v8 algoritması tespit ettiği çürük bölgelerinin %97.70'ini doğru tespit ederken, tespit etmesi gereken çürük bölgelerinin %93.20'sini doğru tespit etmiştir. 344 test görüntüsü COLAB platformunda görüntü başına ortalama 15.3ms ile çok hızlı bir şekilde tespit işlemi yapmaktadır (inference time).

Elde edilen sonuçlara göre YOLO v8 algoritması çürük sınıflarının tespitinde ve lokalizasyonunda başarılı bir performans ortaya koymuştur.

## 5. TARTIŞMA

Yapay zekâ, makinelerin verilen görevleri gerçekleştirmek amacıyla doğal zekâyı ve doğal davranışları taklit etme becerisi olarak tanımlanmaktadır (Hosny ve ark. 2018). Yapay zekâ son yıllarda hızla gelişerek yüksek oranda başarılar ortaya koymuştur. Günlük hayatta birçok konuda kolaylık sağlamıştır ve yaşam alışkanlıklarını etkilemiştir. Çevrimiçi arama motorları, görüntü tanıma ve sanal asistanlar gibi yapay zekâ teknolojileri hayat kalitesini yükselterek insanlara birçok konuda yardımcı olmuştur (Jiang ve ark. 2017). Yapay zekâ toplum için sağlık, finans ve eğitim gibi birçok konuda fayda ve fırsat sağlamaktadır (Wei ve Zhou 2022).

Yapay zekânın gelişmesi ve rutin olarak kullanımı tıp dünyasında da büyük başarılar getirmiştir (Jiang ve ark. 2017). Kanseri teşhisi, prognozu ve tedavileri (Tran ve ark. 2021); tümör tanıları (Jiang ve ark. 2020); klinik oftalmoloji pratiğinde, yaşlanan popülasyonlarda görme bozukluğunun ana nedenlerinin taranması, teşhisi ve takibi (Ting ve ark. 2019); hücre terapisi ve rejeneratif tıp için tek hücreli RNA sıralama analizi (Yan ve ark. 2021) gibi tıbbın her alanında gelişmeye devam etmektedir.

Diş hekimliğinde dijitalleşmenin önemi son 10-20 yılda oldukça artmıştır. Gelişmekte olan ülkelerin çoğunda, tıp ve diş hekimliği uzmanlarının eksikliği, teknolojiye, özellikle de yapay zekâ yazılımına olan ihtiyacı arttırmaktadır. Dijitalleşme; maliyetleri, gerekli muayene ve tedavi zamanını, insan bilgisine olan ihtiyacı ve tıbbi hataların sayısını azaltabilmektedir (Machoy ve ark. 2020)

Yapay zekâ çalışmaları diş hekimliği alanında da kendine geniş çalışma alanları bulmuştur. Periodontolojide; periodontitisin radyografik teşhisinde (Chang ve ark. 2022), oral patolojide; oral eksofoliyatif sitoloji sınıflandırılmasında (Sukegawa ve ark. 2022), oral liken planus lezyonlarının görüntülerinin sınıflandırılmasında (Keser ve ark. 2023), maksillofasiyal cerrahide; mandibula kırıklarının teşhisinde (Son ve ark. 2022), ortognatik cerrahi planlamada yüz dokusu deformasyonunun biyomekanik modellemesinde (Lampen ve ark. 2022), dental implant lokalizasyonlarının

radyografik belirteçlerle otomatik olarak tespitinde (Almalki ve ark. 2022), restoratif tedavide; panoramik radyograflarda derin öğrenmeyi kullanarak diş restorasyonlarının otomatik tespitinde (Çelik ve Çelik 2022), pedodontide; pediatrik panoramik radyograflarda kalıcı diş germ tespitinde (Kaya ve ark. 2022), endodontide; apikal lezyonların teşhisinde (Ekert ve ark. 2019), periapikal ve panoramik dental radyograflarda mandibular ikinci molarların C-şekilli kanallarının sınıflandırılmasında (Yang ve ark. 2022), protetik diş tedavilerinde; silikon çene-yüz protezlerinin renklendirilmesinde (Kurt ve ark. 2023), ortodontide; ortodontik tedavi sırasında kök pozisyonunun üç boyutlu değerlendirmesi için ağız içi taramaları ve dental konik ışınli bilgisayarlı tomografi taramalarını birleştirerek derin öğrenme tabanlı entegre diş modelleri üretiminde (Lee ve ark. 2022), derin öğrenme ile web tabanlı tam otomatik sefalometrik analizde (Kim ve ark. 2020), oral radyolojide; panoramik radyograf görüntülerini kullanılarak diş hastalıklarının sınıflandırılmasında (Almalki ve ark. 2022), panoramik radyograflar üzerinde daimi dişlerin otomatik tespiti ve numaralandırılmasında (Gurses ve ark. 2022), ultrasonografi görüntülerini kullanarak şjögren sendromunu teşhisinde (Kise ve ark. 2020), ağız içi taramadan elde edilen ek bilgileri kullanarak konik ışınli bilgisayarlı tomografide metal artefaktlarının azaltılmasında (Hyun ve ark. 2022) derin öğrenme teknikleri kullanılmıştır. Yapay zekâ çalışmaları ivme kazanarak gelişmeye devam etmektedir (İpek 2019).

Diş çürükleri klinik olarak en sık karşılaşılan diş hastalıklarındandır. Diş çürüğünün prevalansı ve ciddiyeti dünya çapında hala çok yüksektir. Diş çürüğü, yaşam boyu devam edebilen davranışsal, önlenabilir bir hastalıktır (Abdinian ve ark. 2015; Frencken 2018). Diş çürüğü doğru şekilde teşhis edilmediğinde, ilerleyerek mineyi, dentini ve hatta pulpayı işgal edebilir, şiddetli ağrıya neden olabilir ve sonuçta diş fonksiyonunun kaybına yol açabilir. Bu durumlarda restorasyonlar ve protetik tedavi yaşam boyu önemli maliyetlere neden olur (Gannam ve ark. 2018). Diş çürüklerinin erken teşhisi gerekli tedavinin gecikmesini engeller ve sorunların ilerlemesini önler (Schneiderman ve ark. 1997). Lazer floresans kaynaklı yöntemler (QLF, DIAGNOdent), elektriksel iletkenlik ölçümleri, mikro bilgisayarlı tomografi yöntemleri, fiber optik yöntemler (Fiberoptik Transillüminasyon Kaynaklı Yöntemler-FOTI) ve ultrasonik sistemler diş hekimliğinde çürük tespitinde modern yöntemler

olarak uygulamada kendine yer bulmuştur (Korkut ve ark. 2011). Vaarkamp ve arkadaşları bitewing radyograflar ile FOTI'yi karşılaştırmışlardır ve FOTI'nin duyarlılığının bitewing radyograftan önemli ölçüde daha düşük olduğu sonucuna varmışlardır (Vaarkamp ve ark. 2000). Ultrason cihazları, bitewing radyografiye göre interproksimal çürük tespitine karşı oldukça hassastır fakat ultrason cihazları ile çürük tespitinin dezavantajı; diş çürüğünü ancak mine ve dentin yapısında demineralizasyon meydana geldikten sonra tespit edebilmesidir (Matalon ve ark. 2003). Lazer floresan, diğer yöntemlerle karşılaştırıldığında nispeten yüksek duyarlılığa sahiptir ve erken mine çürüklerini teşhis edebilmektedir (El-Housseiny ve Jamjoum 2002). Bununla birlikte, ışık penetrasyonunun olmaması, klinik ortamda kolay uygulanamama ve maddi sebepler nedeniyle, bu sistemlerin hiçbirisi mevcut haliyle çürüklerin tespitinde yeterince etkin değildir (Kamburoğlu ve ark. 2012).

Günümüzde hala bitewing radyografları, radyasyona maruz kalma, ergonomik olmaması dâhil olmak üzere çeşitli dezavantajlara rağmen, interproksimal çürüklerin saptanmasında kullanılan birincil tanı aracı olmaya devam etmektedir (Terry ve ark. 2016). Bitewing radyograflarda çürük lezyonlarını ve restorasyonları saptamak için derin öğrenmenin uygulanması, diş hekimlerinin tedavi planlamasına ve operasyonlara odaklanması için daha fazla klinik zaman kazandırabilir. Ayrıca, yapay zekâ teknolojisi, veri toplamayı ve tıbbi belge kaydını daha verimli hale getirerek veri tabanındaki kayıtları sınıflandırmak için kullanılabilir (Cantu ve ark. 2020).

Yapay zekâ sistemleri, insanın analitik düşüncesini taklit ederek eğitildiği veriler ışığında insan gözüyle ayırt edilebilen veya edilemeyen görüntü özelliklerini nasıl ayırt edebileceğini öğrenir (Pesapane ve ark. 2018). Tanı yöntemi olarak radyografi önerilmesine rağmen, aynı radyograflar kullanıldığında hekimler arasında farklılıklar olabilmektedir. Bu yüzden diş çürüklerinin tespiti bazı durumlarda subjektiftir. Aynı radyograf kullanılarak bile çürük lezyonlarının tespit edilip edilmediği konusunda hekimler arasında büyük farklılıklar vardır. Radyografin kalitesi, görüntüleme koşulları, diş hekiminin beklentileri, muayene eden kişiler arasındaki değişkenlik (özellikle bir diş hekiminin çürük teşhislerine invaziv yaklaşımı) ve muayene başında geçen sürenin uzunluğu gibi faktörler, hekimler arası

anlaşmada tutarsızlıklara neden olur (Langlais ve ark. 1987; Bader ve Shugars 1995). Bilişim uzmanları, yapay zekânın klinik kararları ve süreçleri iyileştirme potansiyeline sahip olduğunu ve bunun ortak veri standartlarıyla objektif olarak yapılabileceğini bildirmişlerdir (Liyanage ve ark. 2019). Sonuç olarak yapay zekâ çalışmalarıyla birlikte çürük tespiti daha objektif olarak tespit edilmektedir (Lian ve ark. 2021).

YOLO son yıllarda yaygın olarak kullanılan bir nesne tespit algoritmasıdır. YOLO, tek bir sinir ağı ile problemi uçtan uca optimize ederek doğrudan algılayarak nesne tespiti yapmaktadır. Nesne tespitinde hız önemli bir kavramdır. YOLO'yu diğer algoritmalarından ayıran gerçek zamanlı nesne tespiti yapmasıdır (Redmon ve ark. 2016). 2015 yılında Redmon ve arkadaşları ilk YOLO versiyonunu tanıtmışlardır (Redmon ve Farhadi 2017). YOLO hedef tespit algoritmasının mantığı, modelin küçük boyutu ve hızlı hesaplama hızında yatmaktadır. YOLO'nun hızı yüksektir, çünkü YOLO'nun nihai algılama sonucunu elde etmek için yalnızca resmi ağı koyması gerekir ve genel bilgiyi kodlayabilen ve nesne olarak arka planı algılama hatasını azaltabilen algılama için doğrudan küresel görüntüyü kullanır. Güçlü bir genelleme yeteneğine sahiptir; çünkü YOLO, diğer alanlara aktarılacak üzere oldukça genelleştirilmiş özellikleri öğrenebilir ancak YOLO'nun nesne tespiti birbirine çok yakın ve grup halindeki nesneler için yetersizdir. Bu zayıf performansın nedeni, nesne tespiti için oluşturulan ızgaradaki yalnızca iki kutunun ve aynı gruptaki nesnelerin tespit edebilmesidir. Bu nedenle YOLO'nun dezavantajı anormal bir en boy oranı olan nesnelerde zayıf genelleme yeteneğidir. YOLO yanlış konumlandırma hatasını da fazla oranda yapmaktadır (Jiang ve ark. 2022).

Geçtiğimiz yıllarda araştırmacılar, YOLO v2, YOLO v3, YOLO v4, YOLO v5, YOLO v6, YOLO v7 olarak tanımlanan gittikçe gelişen YOLO sürümlerini yayınlamışlardır (Redmon ve Farhadi 2017; Bochkovskiy ve ark. 2020; Wang ve ark. 2022; Yan ve ark. 2022). YOLO v2, ağı derinleştirmez veya genişletmez, ancak ağı basitleştirir ve daha hızlıdır. YOLO v3 nesne tespiti için çok ölçekli özelliklerin kullanılması ve temel ağ yapısının ayarlanabilmesi yönüyle YOLO v2'nin geliştirilmiş halidir. YOLO v4 verileri karşılaştırmaya daha fazla odaklanır ve önemli bir iyileşme sağlar. YOLO v5 model boyutunun esnek kontrolü ve veri geliştirme özelliğine

sahiptir (Jiang ve ark. 2022). YOLO v7 aynı çıkarım hızlarında önceki sürümlerden daha yüksek doğrulukla nesne algılayan dikkörtgen kutular çizmektedir (Wang ve ark. 2022). En son geliştirilmiş olan YOLO v8, nesne tespit, görüntü sınıflandırma ve bunlara ek segmentasyon amacıyla kullanılabilir. YOLO v8, eski YOLO sürüm mimarilerine göre çok sayıda mimari içerir. Hızı ve doğruluk oranı iyileştirme içermektedir ve önceki sürümlerine göre en üst düzeydedir (Rath 2023).

YOLO'ya karşı artan ilgi diş hekimliği alanında da kendisine yer edinmiştir. Yapılan bir çalışmada gömülü yirmi yaş dişlerinin panoramik radyograflarda tespiti ve YOLO v3 ile çeşitli derin öğrenme yöntemlerinin (Faster RCNN: ResNET, VGG16, AlexNET) karşılaştırılması yapılmıştır. İki aşamalı nesne tespit algoritmalarından ResNet50, AlexNet ve VGG16 mimarileri ile Faster RCNN ve tek aşamalı nesne tespit algoritması olan YOLO v3 kullanılmıştır. Faster RCNN, ResNet50 ile 0,91 mAP@0,5 değerini verirken, VGG16 ve AlexNet sırasıyla 0,87 ve 0,86 mAP@0,5 değerlerini vermiştir. YOLO v3, 0,96'lık bir mAP@0,5 ile en yüksek algılama performansını göstermiştir. YOLO v3'ün duyarlılık ve kesinlik değerlerini sırasıyla 0,93 ve 0,88 olarak bulunmuştur. YOLO v3 mimarisinin, panoramik radyograflarda gömülü mandibular üçüncü molar diş tespiti için yüksek performansa sahip olduğu görülmüştür (Celik 2022).

Son ve arkadaşları mandibula fraktürlerini derin öğrenme ile teşhis etmek için YOLO v4, UNet, Mask RCNN kullanmışlardır (Son ve ark. 2022). 420 adet mandibula fraktürleri bulunan panoramik radyograflar arasından fraktürleri belirlemeye yarayan 360 adet eğitim verisi görüntüsü seçilmiş ve diğer görüntüler test görüntüleri olarak kullanılmıştır. Son ve arkadaşları kesinlik değerini YOLO v4, UNet, Mask RCNN için sırasıyla 0.75, 0.81, 0.70; duyarlılık değerini 0.96, 0.85, 0.57; F1 skorunu 0.84, 0.83, 0.63 olarak bulmuşlardır. Bu mimarilerin kombine kullanıldığı yöntemde ise kesinliği 0.86, duyarlılığı 0.95, F1 skoru ise 0.90 olarak bulmuşlardır. Mask RCNN, bölge önerilerinin ve sınıflandırmaların sırayla gerçekleştirildiği bir nesne algılama öğrenme yapısına sahip iki aşamalı bir nesne tespiti tekniğidir (He ve ark. 2022). İki aşamalı nesne algılama tekniği genellikle daha doğrudur ancak tek aşamalı algılamaya göre daha yavaştır. Mask RCNN dişler arasındaki boşlukları kırık olarak değerlendirme

eğilimindedir ve genel olarak mandibular kırıkları tespit etme yeteneği, duyarlılık değeri YOLO v4 tekniğinden daha düşük bulunmuştur. YOLO'dan farklı olarak UNet, nesne algılamadan çok görüntü segmente etmek için kullanılan bir mimaridir. UNet, ilk ve sonraki bölümlerde katmana uzun bir atlama bağlantısı ekleyerek konum bilgisi kaybını bir dereceye kadar önleyebilmektedir. YOLO, tamamlanmış fraktürleri tespit edebilmektedir; ancak UNet semantik segmentasyon yaptığı için oblik fraktürleri daha doğru tespit etme avantajına sahiptir. Bu tekniklerin kombine kullanımında algoritmalar birbirinin noksanlıklarını tolere ederek kesinlik ve F1 skorunun değerlerini yükseltmişlerdir.

Literatürdeki bir başka güncel çalışma ise Yüce ve arkadaşlarının yaptığı bitewing radyograflarda pulpa kalsifikasyonlarının derin öğrenme ile otomatik tespitidir. Derin öğrenme algoritmalarından YOLO v4'ü kullanmışlardır ve çalışmanın pulpal kalsifikasyon "yok" ve "var" tespitinde duyarlılık, kesinlik, F1 skoru, doğruluk değerlerini sırasıyla 0.86, 0.85, 0.85, 0.96 olarak hesaplamışlardır (Yuce ve ark. 2022).

Takebe ve arkadaşları mandibular üçüncü molar dişlerin inferior alveolar sinir ile ilişkisini YOLO v3 ile otomatik tespit etmek için 579 panoramik radyograf kullanmışlardır. Yaptıkları çalışmada aynı zamanda YOLO v3'ün performansı ile en az bir yıllık tecrübesi olan beş cerrahın performanslarını karşılaştırmışlardır. YOLO mimarisinin doğruluk, hassasiyet, kesinlik değerleri ve F1 skoru sırasıyla 0.89, 0.92, 0.89, 0.90 olarak hesaplanmıştır. Ağız cerrahlarının metrik değerlerinden doğruluk, hassasiyet, kesinlik değerleri ve F1 skoru sırasıyla 0.62, 0.82, 0.60, 0.69 olarak hesaplanmıştır. Bu çalışmanın sonucunda YOLO v3'ün panoramik radyograflara dayalı diş ve sinir ilişkisini doğrulamak için ek CBCT uygulamaya karar verme sürecinde ağız cerrahlarına yardımcı olabileceğini bildirmişlerdir (Takebe ve ark. 2023).

Uzun Saylan ve arkadaşları periodontal hastalıklarda alveolar kemik kaybını teşhis etmek için 685 adet panoramik radyografda periodontal kemik kaybı alanlarını tespit eden ve segmentasyon yöntemiyle etiketleyen, CranioCatch yazılımı aracılığıyla

uygulanan PyTorch tabanlı YOLO v5 mimarisini kullanmışlardır. Çalışmada etiketleme bir radyolog ve bir periodontolog tarafından yapılmıştır. Maksilladaki kesici, kanin, premolar ve molar dişlerdeki kesinlik değerlerini sırasıyla; 0.90, 0.81, 0.69, 0.96, duyarlılık değerlerini sırasıyla 1, 0.88, 0.94, 0.87 ve F1 skorlarını sırasıyla 0.95, 0.84, 0.80, 0.91 olarak hesaplamışlardır. Mandibuladaki kesici, kanin, premolar ve molar dişlerdeki kesinlik değerlerini sırasıyla; 0.89, 0.78, 0.75, 0.73, duyarlılık değerlerini sırasıyla 0.83, 0.92, 0.83, 0.85 ve F1 skorlarını sırasıyla 0.86, 0.84, 0.79, 0.79 olarak hesaplamışlardır (Uzun Saylan ve ark. 2023). YOLO v5 mimarisinin kullanıldığı bu çalışma YOLO v4 mimarisi kullanılan çalışmaya oranla yüksek performans değerleri ortaya koymuştur (Jiang ve ark. 2022).

Literatürde diş hekimliği alanında YOLO algoritmasının kullanıldığı çeşitli çalışmalar bulunmakla birlikte (Son ve ark. 2022; Yuce ve ark. 2022; Kaya ve ark. 2023) YOLOv8 ile gerçekleştirilen bir çalışma bulunmamaktadır. İçerdiği iyileştirmeler sonucu hız ve doğruluk oranında artış nedeniyle çalışmamızda YOLOv8'in çürük tanısındaki başarısı araştırılmıştır.

Lee ve arkadaşları derin öğrenme algoritmalarından GoogleNET Inception v3 CNN kullanarak periapikal radyograflarda çürük tespiti çalışması yapmışlardır. 3000 periapikal radyograftan oluşan veri setini kullanmışlardır. Premolar ve molar dişlerde, her ikisinde doğruluk değerlerini sırasıyla 0.89, 0.88, 0.82; duyarlılık değerlerini 0.84, 0.92, 0.81; kesinlik değerlerini 0.93, 0.85, 0.82 olarak bulmuşlardır. Bu çalışmanın kısıtlı yönlerinden birisi düşük çözünürlüklü periapikal (299x299 piksel) radyografların kullanılmasıdır (Lee ve ark. 2018). Takahashi ve arkadaşları bir çalışmada periapikal ve bitewing radyografların interproksimal çürük tespitindeki başarılarını karşılaştırmıştır. Bitewing radyograflar interproksimal çürüklerin erken evrelerinin teşhisinde periapikal radyograflara göre önemli oranda başarılıdır (Takahashi ve ark. 2019). Bu yüzden günümüzde çürük tanısında hala altın standart olan bitewing radyografi (Korkut ve ark. 2011) çalışmamızda tercih edilmiştir. İki aşamalı nesne tespit algoritmalarından GoogleNET kullanılan bu çalışmaya kıyasla tek aşamalı nesne tespit algoritmalarından YOLO v8 kullandığımız çalışmamızda

YOLO'nun hız avantajına ek olarak; doğruluk, kesinlik ve duyarlılık değerlerimiz sırasıyla 0.96, 0.96, 0.96 olup daha yüksektir.

Bazı araştırmacılar literatürde çürük tespitini konu alan yapay zekâ çalışmalarında panoramik radyograflar kullanmıştır (Lian ve ark. 2021; Zhu ve ark. 2022). Lian ve arkadaşları interproksimal çürükleri tespit etmek için UNet algoritmasını; derinliklerine göre sınıflandırmak için (d1-d2-d3) DenseNet121 mimarisini kullanmışlardır. Çalışmalarında 1160 panoramik radyograf kullanmışlardır ve altı uzman diş hekiminin tanılarına göre sonuçları karşılaştırmışlardır. UNet ve diş hekimlerinin sırasıyla kesinlik değeri; 1, 0.70, duyarlılık değeri 0.82, 0.77, F1 skoru; 0.90, 0.73 olarak hesaplanmıştır. DenseNet ve diş hekimlerinin d1 interproksimal çürüğü için sırasıyla kesinlik değeri; 0.81, 0.79, duyarlılık değeri 0.76, 0.46, F1 skoru; 0.78, 0.57 olarak hesaplanmıştır. d2 interproksimal çürüğü için sırasıyla kesinlik değeri; 0.73, 0.60, duyarlılık değeri 0.65, 0.53, F1 skoru; 0.69, 0.56 olarak hesaplanmıştır. d3 interproksimal çürüğü için sırasıyla kesinlik değeri; 0.86, 0.84, duyarlılık değeri 0.91, 0.94, F1 skoru; 0.89, 0.89 olarak hesaplanmıştır. Bu çalışma çürükleri tespit etme ve derinliğe göre sınıflandırma konusunda uzman diş hekimlerine benzer şekilde performans göstermiştir (Lian ve ark. 2021). Sekonder, okluzal, d1 interproksimal, d2 interproksimal, d3 interproksimal çürükleri YOLO v8 mimarisi kullanarak tespit ettiğimiz bu çalışmada ise kesinlik değeri sırasıyla 0.96, 0.99, 0.96, 0.97, 0.90; duyarlılık değeri sırasıyla 0.95, 0.93, 0.95, 0.96, 1; F1 skor sırasıyla 0.96, 0.96, 0.96, 0.95 olarak hesaplanarak bu çalışmaya göre daha yüksek performans metrik değerleri elde edilmiştir. Ayrıca panoramik radyograflar intraoral radyografi tekniklerine göre ayrıntıyı göstermede, magnifikasyon ve süperpozisyon hatalarını engellemede bitewing radyografiye göre daha yetersizdir (White ve Pharoah 2014).

Cantu ve arkadaşları bitewing radyograflarda çürük tespiti için bir grup (7 klinisyen) muayenehane hekiminin tanıları ile yapay zekâ algoritmalarından UNet'i karşılaştırmışlardır. Çalışmanın veri setinde 3686 bitewing radyograf bulunmaktadır. Bitewing radyograflar üzerinde çürüğün derinliğine göre e1, e2, d1, d2, d3 (e: mine derinliği; d: dentin derinliği) etiketleri yapılmıştır. Çalışma sonucunda yapay zekânın doğruluk değeri, duyarlılık değeri, F1 skoru ortalama olarak sırasıyla 0.80, 0.75, 0.73

olarak bulunmuştur. En az üç yıllık deneyimi olan klinisyenlerin ise doğruluk değeri, duyarlılık değeri, F1 skoru sırasıyla 0.71, 0.36, 0.41 olarak bulunmuştur. Bu çalışmada yapay zekâ algoritması UNet çürükleri tespit etmede hekimlere göre daha yüksek performans değerleri ortaya koymuştur (Cantu ve ark. 2020).

Lee ve ark. interproksimal çürükleri bitewing radyograflarda segmentlere ayırmak için UNet derin öğrenme mimarisini kullanmışlardır. 304 eğitim 50 test verisi olmak üzere 354 bitewing radyograf kullanmışlardır. Çalışmanın kesinlik değeri 0.63, duyarlılık değeri 0.65, F1 skoru 0.64 olarak tespit edilmiştir. Çalışmada interproksimal çürüklerin yanı sıra kök çürükleri ve sekonder çürükler de tespit edilmiştir. Bu çalışmanın sınırlı yönlerinden birisi veri setinin az olmasıdır, çalışma sonucunda elde edilen performans değerleri nispeten düşüktür (Lee ve ark. 2021). Bir derin öğrenme ağı çok sayıda veri kümesi ve bilgi işlem gücü gerektirir. UNet, KSA için en önemli segmentasyon mimarilerinden birisidir; ancak veri seti çok az ise ve bilgi işlem gücü yetersizse, ağı eğitmek için daha fazla zamana ihtiyaç olacaktır (Du ve ark. 2020). Bayrakdar ve arkadaşları VGG16 ve UNet mimarisi kullanılarak bitewing radyograflarda KSA algoritmalarına dayalı otomatik çürük tespitini yapmak ve segmentasyon modeli önermek ve modelin klinik performansını beş diş hekimine göre değerlendirme amacıyla yürüttükleri çalışmada; 621 bitewing radyograf kullanmışlardır. Çürük tespiti için duyarlılık, kesinlik ve F1 skoru değerlerini 0.84, 0.84, 0.84 ve ayrıca çürük segmentasyonu için duyarlılık, kesinlik ve F1 skoru değerlerini 0.81, 0.86, 0.84 olarak hesaplamışlardır. 5 farklı diş hekimi yapay zeka mimarisi ile karşılaştırıldığında, yapay zeka mimarileri hekimlere göre üstünlük göstermiştir. Çalışmanın kısıtlı yönlerinden birisi örneklem büyüklüğünün literatürdeki diğer çalışmalara kıyasla daha düşük olmasıdır (Bayrakdar ve ark. 2022). YOLO v8 ile bu çalışmada YOLO'nun hızlı olma avantajının yanı sıra ortalama kesinlik, duyarlılık, F1 skor değerleri sırasıyla 0.96, 0.96, 0.96 olarak bu çalışmalara göre daha başarılı bir sonuç elde etmiştir.

Chen ve arkadaşları interproksimal çürükleri bitewing radyograflarda seviyelerine (e1-e2-d1-d2-d3) göre derin öğrenme ile tespit etmiştir. 818 eğitim verisi, 160 test verisi olmak üzere 978 bitewing radyograf kullanılmıştır. Bu çalışmada

çürükler iki endodontist ve bir radyolog tarafından etiketlenmiştir. Yapay zekâ algoritmalarından Faster RCNN’i kullanmışlardır. Yapay zekâ algoritmasının sonuçları ile lisansüstü öğrencilerin çalışmaları karşılaştırılmıştır. Algoritma test verilerinde kesinlik değeri 0.87, duyarlılık değeri 0.72, F1 skoru 0.74 olarak; lisansüstü öğrencilerin test verilerinde kesinlik değeri 0.82, duyarlılık değeri 0.47, F1 skoru 0.57 olarak tespit edilmiştir. Lisansüstü öğrencilerin performans metrik değerleri Faster RCNN’e göre anlamlı derece düşük bulunmuştur (Chen ve ark. 2022). Estai ve arkadaşları bitewing radyograflarda interproksimal çürüklerin tespiti için Faster RCNN algoritmalarından Inception ResNet v2 mimarisini kullanmışlardır. Veri setinde 1257’inde çürük bulunan 1211’i sağlıklı dişlerden oluşan 2468 bitewing radyograf bulunmaktadır. Potansiyel çürük bölgelerini tespit etmek için 13.246 ROI üretmişlerdir. Çürük bulunan bitewing radyografların yarısını ROI tespit modülünü eğitmek için diğer yarısını doğrulamak için kullanmışlardır. Çalışmalarında kesinlik değeri 0.86, duyarlılık değeri 0.89, F1 skoru 0.87 değerinde olup literatürde yüksek oranda başarı sağlamışlardır (Estai ve ark. 2022). Inception Resnet v2 CNN modeli, diğer Faster RCNN mimarilerine göre daha etkin tespit yapabilmektedir (Kamble ve ark. 2018). Faster RCNN iki aşamalı nesne tespit algoritmalarından birisidir ve gündelik hayatta düşük gerçek zamanlı performansı dezavantajlarından biridir. Ayrıca Faster RCNN’nin selektif arama algoritmasından dolayı hatalı nesne tespiti yapma sorunu da vardır (Maity ve ark. 2021; Yan ve ark. 2022). Çalışmamızda nesne tespit doğruluğu ve hız arasında iyi bir denge sağladığı için tek aşamalı nesne tespit algoritmalarından YOLO v8 mimarisi kullanılmıştır (Kim ve ark. 2023). Ayrıca YOLO v8 kullandığımız çalışmamızın performans değerleri (kesinlik, 0.96; duyarlılık, 0.96; F1 skor, 0.96) Faster RCNN kullanılan bu çalışmalara göre daha yüksektir.

Mao ve arkadaşları bitewing radyograflar üzerinde restorasyonları ve çürükleri sınıflandırmak için KSA mimarilerinden olan AlexNet’i kullanmışlardır. Kesinlik değerini 0.95 ve duyarlılık değerini 0.90 bulmuşlardır. AlexNet’in dezavantajlarından biri çok fazla nörona sahip olması ve artan model karmaşıklığına ve hatalı nesne tespitine yol açabilmesidir. Bu da hesaplama süresini arttırır ve verimliliği düşürür (Mao ve ark. 2021). Mao ve arkadaşları AlexNet’in bu dezavantajlarını elimine edebilmek için 278 bitewing radyograf görüntüleri keserek 3716 unilateral diş

radyograf görüntüsü elde etmişlerdir ve aynı zamanda geliştirilen algoritmanın hesaplama karmaşıklığını azaltmak için tek taraflı dış görüntülerini kullanmışlardır ancak bunun sonucu olarak veri setinde dengesizlik oluşmuştur (Mao ve ark. 2021). Bu çalışmanın sonuç performans değerleri yüksek görünmekle birlikte veri setinin homojen ve dengeli bölünmesi yapay zekâ çalışmalarının performansını arttıran mühim bir husustur (Koçoğlu ve Ozcan 2018).

KSA'lar sıklıkla görüntüleri tanımak ve sınıflandırmak için kullanılan derin öğrenme mimarisidir. Beyindeki nöral süreçleri taklit etmek üzere tasarlanmış bir ileri beslemeli sinir ağı türü olan KSA, genelde görüntü işleme görevlerine uygulanır (Egmont-Petersen 2002). Bu durumlarda, görüntüyü kontrast, çizgiler, renk, şekiller gibi gruplara dönüştürerek ve ardından bu grupları çeşitli şekillerde birleştirerek görüntünün farklı yönlerine göre alt örneklere ayırır (LeCun ve ark. 2015). Görüntü algılamada en sık kullanılan KSA mimarileri arasında RCNN, Faster RCNN ve YOLO bulunur. Nesne tespit mimarileri, nesne kenarı tespiti için birden çok sınırlayıcı kutu kullanarak, bir görüntüden hedeflenen içeriği geleneksel KSA'lardan nispeten daha hızlı bir oranda sınıflandırabilir, bulabilir ve tanımlayabilir. (Corbella ve ark. 2021).

Görüntü segmentasyonu, bir görüntüdeki hedeflenen nesnenin arka planından ayrıldığı benzer ilkelerin uygulanmasıyla elde edilen, görüntü algılamının başka bir çeşididir. Görüntü segmentasyonu, semantik ve örnek segmentasyonu içerir. Semantik segmentasyonda, aynı kategoriye ait çok sayıda nesne tek bir varlık olarak kabul edilir. Örnek segmentasyon durumunda, aynı kategorideki birden çok nesnenin ayrı ve ayrı nesneler olduğu kabul edilir. Görüntü segmentasyonu için sık kullanılan bazı mimariler, KSA ve UNet'tir (Corbella ve ark. 2021). Dış hekimliğinde görüntü segmentasyonuna ilişkin olarak, araştırmacılar; panoramik radyograflarda apikal lezyon segmentasyonu (Bayrakdar ve ark. 2022), bitewing radyograflarda erken diş çürüğü tespiti (Lee ve ark. 2021), dental bitewing radyograflarının değerlendirilmesinde UNet yaklaşımları (Baydar ve ark. 2023), dental periapikal radyografların otomatik özellik segmentasyonu (Ari ve ark. 2022), dental bitewing radyograflarda çürük tespiti ve segmentasyonu (Bayrakdar ve ark. 2022), sürekliliğe duyarlı bir bağlamsal ağ kullanarak CBCT görüntülerinde mandibular kanalın

otomatik ve güçlü üç boyutlu segmentasyonu (Jeoun ve ark. 2022) konulu çalışmalar yapmıştır. Nesne tespiti ve görüntü segmentasyonu, her ikisi de bir görüntü içindeki nesnelerin tespitini ve lokalizasyonunu içeren ilgili görevlerdir; ancak görüntü segmentasyonu radyolog tarafından sadece sıkıcı ve zaman alıcı bir süreç olmakla kalmaz, aynı zamanda özellikle artan tıbbi görüntüleme yöntemleri ve incelenmesi gereken çok fazla miktarda tıbbi görüntü ile pratik değildir. Bu nedenle, özellikle tıbbi görüntüler için doğru olan ve mümkün olduğunca az kullanıcı etkileşimi gerektiren otomatik nesne tespiti algoritmalar kullanarak mevcut görüntü segmentasyon metodolojilerini gözden geçirmek gerekli hale gelir (Patil ve Deore 2013). Bu nedenle çalışmamızda çürükleri segmente etmek yerine YOLOv8 nesne tespit algoritması kullanarak derin öğrenmenin oral radyolog ile karşılaştırıldığında tespit başarısını belirlemeyi hedefledik. Ayrıca YOLO, UNet ve ResNet gibi diğer birçok segmentasyon modelinden çok daha hızlıdır (Paikar 2013). Hızlı ve doğru teşhisin ağız ve diş sağlığı üzerine doğrudan etkisi olduğundan dolayı YOLOv8 kullanarak diş hekimlerinin daha hızlı ve daha doğru kararlar vermesini sağlayabiliriz.

Bu çalışma bitewing radyograflar üzerinden sekonder, okluzal, interproksimal (d1-d2-d3) çürük tespitinde derin ağ mimarisi olan YOLO v8'in başarısını belirlemeyi hedeflemiştir. Bunun için 860 bitewing kullanılmıştır. Yapay zekâ çalışmalarında kullanılan veri setlerinin olabildiğince homojen ayrılması kullanılan algoritmanın performansını arttırmaktadır (Koçoğlu ve Özcan 2018); ancak bu çalışmanın limitasyonu olarak test verilerinde doğru pozitif etiketlerin dağılımı sekonder çürük 104, oklüzal çürük 54, d1 interproksimal çürük 218, d2 interproksimal çürük 315, d3 interproksimal çürük 46 olmak üzere heterojendir. Dengesiz veri seti ile test, eğitim ve validasyon yapılmış olmasına rağmen, eğitim ve validasyonun doğruluğu ortalama değerleri 0.97, kesinliği 0.96, duyarlılığı 0.96, F1 skoru 0.96, mAp değeri 0.96 bulunmuştur. Sekonder, okluzal, d1 interproksimal, d2 interproksimal, d3 interproksimal çürükleri eğitim ve validasyon sonucu elde edilen kesinlik değeri sırasıyla 0.96, 0.99, 0.96, 0.97, 0.90; duyarlılık değeri sırasıyla 0.95, 0.93, 0.95, 0.96, 1; F1 skor sırasıyla 0.96, 0.96, 0.96, 0.96, 0.95; mAP.5 değeri 0.96, 0.96, 0.97, 0.97, 0.95 olarak hesaplanmıştır. Değerlerin %100'e yakın olması sistem performansının yüksek oranda başarılı olduğunu göstermektedir. Çalışmamızda YOLOv8 çürük

bulunmayan bir alanı çürük olarak tanımlamamıştır. Ayrıca kullanılan derin öğrenme metodunda elde edilen yapay zekâ ağırlık dosyaları ile sisteme hiç veri olarak girilmeyen çürükler tespit edilebilmiştir. Literatürde daha önce aynı çalışma içerisinde okluzal, sekonder ve interproksimal çürükleri tespit edip sınıflandıran (d1-d2-d3) benzeri bir çalışma bulunmamaktadır.

Çalışma kapsamında geliştirdiğimiz ara yüzün öncelikle yeterli oral radyoloji tecrübesi bulunmayan klinisyenlerin ve klinik eğitim gören diş hekimliği öğrencilerinin pratiğinde kullanımı amaçlanmaktadır. Bu arayüz özellikle teşhiste gözden kaçan çürüklerin tespitinde yararlı olabilecektir. Geliştirilen bu arayüz şu an için yalnızca çürük teşhisi yapmaktadır. Yakın gelecekte diğer dental radyolojik tanıların da ara yüze eklenmesi ile eğitim simülatörü gibi kullanılacak bir programa dönüştürülmesi hedeflenmektedir.

## 6. SONUÇLAR VE ÖNERİLER

YOLOv8’de gerçekleşen iyileştirmelerin katkısı ile bitewing radyograflarda çürük tespiti ve sınıflandırılması (sekonder, okluzal, d1 interproksimal, d2 interproksimal, d3 interproksimal) yüksek tanısal performans değerleri ile gerçekleştirilebilmektedir. Klinik için oluşturulan arayüz özellikle başlangıç aşamasında iken gözden kaçırılabilen çürüklerin tespitinde diş hekimine yardımcı olarak hekimin iş yükünü azaltabilir, çürük lezyonuna yönelik tedavi ve takip planı oluşturulmasında hekime yol göstericidir.



## 7. KAYNAKLAR

- Abbod MF, von Keyserlingk DG, Linkens DA, Mahfouf M. Survey of utilisation of fuzzy technology in medicine and healthcare. *Fuzzy Sets Systems*. 2001; 120(2): 331-49.
- Abdinian M, Razavi SM, Faghihian R, Samety AA, Faghihian E. Accuracy of Digital Bitewing Radiography versus Different Views of Digital Panoramic Radiography for Detection of Proximal Caries. *J Dent*. 2015; 12(4): 290-7.
- Abou Neel EA, Aljabo A, Strange A et al. Demineralization-remineralization dynamics in teeth and bone. *Int J Nanomedicine*. 2016; 11: 4743-63.
- Albawi S, Mohammed TA, Al-Zawi S Understanding of a convolutional neural network. pp. 1-6; pp. 1-6.
- Allahverdi N (2002) *Uzman Sistemler: Bir Yapay Zeka Uygulaması*: Atlas Yayın Dağıtım.
- Almalki YE, Din AI, Ramzan M et al. Deep Learning Models for Classification of Dental Diseases Using Orthopantomography X-ray OPG Images. *Sensors*. 2022; 22(19).
- AlShehab AH, AlHazoom AA, Alowa MH, AlAli HA, Abdulmohsen AA, Farooq I. Effect of bristle stiffness of manual toothbrushes on normal and demineralized human enamel-An in vitro profilometric study. *Int J Dent Hyg*. 2018; 16(2): e128-e32.
- Aminoshariae A, Kulild J, Nagendrababu V. Artificial Intelligence in Endodontics: Current Applications and Future Directions. *J Endod*. 2021; 47(9): 1352-7.
- Anderson DM, George Artificial neural networks technology. Kaman Sciences Corporation. 1992; 258(6): 1-83.
- Angelova Volponi A, Zaugg LK, Neves V, Liu Y, Sharpe PT. Tooth Repair and Regeneration. *Curr Oral Health Rep*. 2018; 5(4): 295-303.
- Ari T, Sağlam H, Öksüzoğlu H et al. Automatic Feature Segmentation in Dental Periapical Radiographs. *Diagnostics* 2022; 12(12).
- Arnold WH, Konopka S, Kriwalsky MS, Gaengler P. Morphological analysis and chemical content of natural dentin carious lesion zones. *Ann Anat*. 2003; 185(5): 419-24.
- Aytekin A, Ayaz A, Tüminçin F İnsan beyni modellenmesi ve yapay sinir ağları. 2019 International Social Research and Behavioral Sciences Symposium.
- Babalık A, Güler İ. Boğaz Enfeksiyonlarının Teşhis ve Tedavisinde Uzman Sistem Kullanımı. *Selcuk University Journal of Engineering Sciences*. 2007; 6(2): 109-19.
- Bader JD, Shugars DA. Variation in dentists' clinical decisions. *Journal of public health dentistry*. 1995; 55(3): 181-8.
- Baelum V, Heidmann J, Nyvad B. Dental caries paradigms in diagnosis and diagnostic research. *Eur J Oral Sci*. 2006; 114(4): 263-77.
- Barhoom AMA, Abu-Naser SS. Diagnosis of Pneumonia Using Deep Learning. *International Journal of Academic Engineering Research*. 2022; 6: 48-68.
- Barro S, Marín R (2001) *Fuzzy logic in medicine*: Springer Science & Business Media.
- Batra P, Saini P, Yadav V. Oral health concerns in India. *J Oral Biol Craniofac Res*. 2020; 10(2): 171-4.
- Baydan B. Derin öğrenme ile köpek ve kedi tibia kemikleri üzerindeki kırıkların tespiti ve sınıflandırması. 2021.
- Baydar O, Rózyło-Kalinowska I, Futyma-Gąbka K, Sağlam H. The U-Net Approaches to Evaluation of Dental Bite-Wing Radiographs: An Artificial Intelligence Study. *Diagnostics* 2023; 13(3).
- Bayrakdar IS, Orhan K, Akarsu S et al. Deep-learning approach for caries detection and segmentation on dental bitewing radiographs. *Oral Radiol*. 2022; 38(4): 468-79.
- Bayrakdar IS, Orhan K, Çelik Ö et al. A U-Net Approach to Apical Lesion Segmentation on Panoramic Radiographs. *Biomed Res Int*. 2022; 2022: 7035367.
- Belacel N, Boulassel MR. Multicriteria fuzzy classification procedure PROCFTN: methodology and medical application. *Fuzzy Sets Systems*. 2004; 141(2): 203-17.

- Bellman R (1978) An introduction to artificial intelligence: can computers think?: Thomson Course Technology.
- Bochkovskiy A, Wang C-Y, Liao H-YM. Yolov4: Optimal speed and accuracy of object detection. arXiv preprint arXiv. 2020: 10934.
- Bozdemir E, Yarbasi Ö. Tanıda sadece panoramik radyografi ne kadar güvenli? Selcuk Dental Journal. 2019; 6(4): 100-3.
- Brandt ME, Bohant TP, Kramer LA, Fletcher JM. Estimation of CSF, white and gray matter volumes in hydrocephalic children using fuzzy clustering of MR images. Computerized medical imaging graphics. 1994; 18(1): 25-34.
- Caldeira CP (2007) Introduction to Information Systems: Supporting and Transforming Business. pp. 432: Pergamon.
- Cantu AG, Gehrung S, Krois J et al. Detecting caries lesions of different radiographic extension on bitewings using deep learning. J Dent. 2020; 100: 103425.
- Cehreli SB, Gungor HC, Karabulut E. Er, Cr: YSGG laser pretreatment of primary teeth for bonded fissure sealant application: a quantitative microleakage study. Journal of Adhesive Dentistry. 2006; 8(6).
- Celik ME. Deep Learning Based Detection Tool for Impacted Mandibular Third Molar Teeth. Diagnostics 2022; 12(4).
- Chang J, Chang MF, Angelov N et al. Application of deep machine learning for the radiographic diagnosis of periodontitis. Clin Oral Investig. 2022; 26(11): 6629-37.
- Charniak E, McDermott DJR, MA. Introduction to artificial intelligence. addison. 1985.
- Chatzistavrou X, Papagerakis S, Ma PX, Papagerakis P. Innovative approaches to regenerate enamel and dentin. Int J Dent. 2012; 2012: 856470.
- Chen SH, Jakeman AJ, Norton JP. Artificial Intelligence techniques: An introduction to their use for modelling environmental systems. Mathematics and Computers in Simulation. 2008; 78(2): 379-400.
- Chen X, Guo J, Ye J, Zhang M, Liang Y. Detection of Proximal Caries Lesions on Bitewing Radiographs Using Deep Learning Method. Caries Res. 2022; 56(5-6): 455-63.
- Chi C-L, Street WN, Ward MM. Building a hospital referral expert system with a prediction and optimization-based decision support system algorithm. Journal of biomedical informatics. 2008; 41(2): 371-86.
- Comendador BEV, Francisco BMB, Medenilla JS, Mae S. Pharmabot: a pediatric generic medicine consultant chatbot. Journal of Automation Control Engineering. 2015; 3(2).
- Corbella S, Srinivas S, Cabitza F. Applications of deep learning in dentistry. Oral Surg Oral Med Oral Pathol Oral Radiol. 2021; 132(2): 225-38.
- Coşkun M, Yıldırım Ö, Ayşegül U, Demir Y. An overview of popular deep learning methods. European Journal of Technique. 2017; 7(2): 165-76.
- Cross NJDs. Natural intelligence in design. 1999; 20(1): 25-39.
- Çelik B, Çelik ME. Automated detection of dental restorations using deep learning on panoramic radiographs. Dentomaxillofac Radiol. 2022; 51(8): 20220244.
- Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. Future Healthc J. 2019; 6(2): 94-8.
- Davenport TH, Ronanki RJH. Artificial intelligence for the real world. 2018; 96(1): 108-16.
- Deng L. Deep learning: methods and applications. Foundations Trends Signal Process. 2014; 7(3-4): 197-387.
- Deng L. A tutorial survey of architectures, algorithms, and applications for deep learning. APSIPA Transactions on Signal and Information Processing. 2014; 3: e2.
- Di Lascio L, Gisolfi A, Albunia A, Galardi G, Meschi F. A fuzzy-based methodology for the analysis of diabetic neuropathy. Fuzzy Sets Systems. 2002; 129(2): 203-28.

- Dickerson J. The characterization of stroke subtype and science of evidence-based medicine using fuzzy logic. *Journal of Neurovascular Disease*. 1997; 2: 138-44.
- Downer M. Validation of methods used in dental caries diagnosis. *Int Dent J*. 1989; 39(4): 241-6.
- Du G, Cao X, Liang J, Chen X, Zhan Y. Medical image segmentation based on u-net: A review. *Journal of Imaging Science Technology*. 2020.
- Egmont-Petersen MdR, Dick Handels, Heinz. Image processing with neural networks. *Pattern recognition*. 2002; 35(10): 2279-301.
- Ekert T, Krois J, Meinhold L et al. Deep Learning for the Radiographic Detection of Apical Lesions. *J Endod*. 2019; 45(7): 917-22.e5.
- Ekstrand K, Qvist V, Thylstrup A. Light microscope study of the effect of probing in occlusal surfaces. *Caries Res*. 1987; 21(4): 368-74.
- Ekstrand K, Ricketts D, Kidd E. Reproducibility and accuracy of three methods for assessment of demineralization depth on the occlusal surface: an in vitro examination. *Caries Res*. 1997; 31(3): 224-31.
- El-Housseiny A, Jamjoum H. Evaluation of visual, explorer, and a laser device for detection of early occlusal caries. *Journal of Clinical Pediatric Dentistry*. 2002; 26(1): 41-8.
- Elmas Ç. Yapay sinir ağları. 2003.
- Ertl L, Christ F. Significant improvement of the quality of bystander first aid using an expert system with a mobile multimedia device. *Resuscitation*. 2007; 74(2): 286-95.
- Estai M, Tennant M, Gebauer D et al. Evaluation of a deep learning system for automatic detection of proximal surface dental caries on bitewing radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2022; 134(2): 262-70.
- Exarchos TP, Tsipouras MG, Exarchos CP, Papaloukas C, Fotiadis DI, Michalis LK. A methodology for the automated creation of fuzzy expert systems for ischaemic and arrhythmic beat classification based on a set of rules obtained by a decision tree. *Artif Intell Med*. 2007; 40(3): 187-200.
- Featherstone JD. The caries balance: the basis for caries management by risk assessment. *Oral Health Prev Dent*. 2004; 2 Suppl 1: 259-64.
- Featherstone JD. Dental caries: a dynamic disease process. *Aust Dent J*. 2008; 53(3): 286-91.
- Fejerskov O, Nyvad B, Kidd E (2015) Dental caries: the disease and its clinical management: John Wiley & Sons.
- Ferracane JL. Models of Caries Formation around Dental Composite Restorations. *J Dent Res*. 2017; 96(4): 364-71.
- Frencken J. Caries Epidemiology and Its Challenges. *Monogr Oral Sci*. 2018; 27: 11-23.
- Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological cybernetics*. 1980; 36(4): 193-202.
- Gannam CV, Chin KL, Gandhi RP. Caries risk assessment. *Gen Dent*. 2018; 66(6): 12-7.
- Gershman SJ, Horvitz EJ, Tenenbaum JBJS. Computational rationality: A converging paradigm for intelligence in brains, minds, and machines. 2015; 349(6245): 273-8.
- Girshick R, Donahue J, Darrell T, Malik J Rich feature hierarchies for accurate object detection and semantic segmentation. pp. 580-7; pp. 580-7.
- Girshick R, Donahue J, Darrell T, Malik J. Region-based convolutional networks for accurate object detection and segmentation. *IEEE transactions on pattern analysis machine intelligence*. 2015; 38(1): 142-58.
- Gladwin MA, Stewart MA, Bagby MD (2009) Clinical aspects of dental materials: theory, practice, and cases: Lippincott Williams & Wilkins.
- Glauner PO. Deep convolutional neural networks for smile recognition. *arXiv preprint*. 2015: 06535.
- Goldberg M (2016) The Early Enamel Carious Lesion. *Understanding Dental Caries*, pp. 29-39: Springer.

- Goletsis Y, Papaloukas C, Fotiadis DI, Likas A, Michalis LK. Automated ischemic beat classification using genetic algorithms and multicriteria decision analysis. *IEEE transactions on Biomedical Engineering*. 2004; 51(10): 1717-25.
- Goodfellow I, Bengio Y, Courville A (2016) Deep learning: MIT press.
- Graves A, Liwicki M, Fernández S, Bertolami R, Bunke H, Schmidhuber J. A novel connectionist system for unconstrained handwriting recognition. *IEEE transactions on pattern analysis machine intelligence*. 2008; 31(5): 855-68.
- Graves A, Mohamed A-r, Hinton G Speech recognition with deep recurrent neural networks. pp. 6645-9; pp. 6645-9. *Ieee*.
- Gurses BO, Sener E, Guneri P. Deep learning for automated detection and numbering of permanent teeth on panoramic images. *Dentomaxillofac Radiol*. 2022; 51(5): 20220128.
- Guzmán-Armstrong S. Rampant caries. *J Sch Nurs*. 2005; 21(5): 272-8.
- Gündüz K. Çürük tanısında kullanılan yeni yöntemler. *Cumhuriyet Üniversitesi Diş Hekimliği Fakültesi Dergisi*. 2003; 6: 1.
- Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism*. 2017; 69s: S36-s40.
- Harun P. Yapay zeka. *Yaşar Üniversitesi E-Dergisi*. 2006; 1(1): 81-93.
- Harzallah H, Jurie F, Schmid C Combining efficient object localization and image classification. pp. 237-44; pp. 237-44.
- Haugeland J (1989) Artificial intelligence: The very idea: MIT press.
- He H, Xu H, Zhang Y et al. Mask R-CNN based automated identification and extraction of oil well sites. *International Journal of Applied Earth Observation Geoinformation*. 2022; 112: 102875.
- He K, Gkioxari G, Dollár P, Girshick R Mask r-cnn. pp. 2961-9; pp. 2961-9.
- Heo MS, Kim JE, Hwang JJ et al. Artificial intelligence in oral and maxillofacial radiology: what is currently possible? *Dentomaxillofac Radiol*. 2021; 50(3): 20200375.
- Hickel R, Peschke A, Tyas M et al. FDI World Dental Federation: clinical criteria for the evaluation of direct and indirect restorations—update and clinical examples. *Clin Oral Investig*. 2010; 14(4): 349-66.
- Hicks J, Garcia-Godoy F, Donly K, Flaitz C. Fluoride-releasing restorative materials and secondary caries. *CDA*. 2003; 31(3): 229-46.
- Hicks J, Garcia-Godoy F, Flaitz C. Biological factors in dental caries: role of remineralization and fluoride in the dynamic process of demineralization and remineralization (part 3). *Journal of Clinical Pediatric Dentistry*. 2004; 28(3): 203-14.
- Hicks M, Flaitz C. Epidemiology of dental caries in the pediatric and adolescent population: a review of past and current trends. *The Journal of clinical pediatric dentistry*. 1993; 18(1): 43-9.
- Hinton GE. Training products of experts by minimizing contrastive divergence. *Neural computation Communications of the ACM*. 2002; 14(8): 1771-800.
- Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks. *Science*. 2006; 313(5786): 504-7.
- Hoi SC, Wu X, Liu H et al. Logo-net: Large-scale deep logo detection and brand recognition with deep region-based convolutional networks. *arXiv preprint*. 2015: 02462.
- Holmgren C, Roux D, Doméjean S. Minimal intervention dentistry: part 5. Atraumatic restorative treatment (ART)—a minimum intervention and minimally invasive approach for the management of dental caries. *Br Dent J*. 2013; 214(1): 11-8.
- Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts H. Artificial intelligence in radiology. *Nat Rev Cancer*. 2018; 18(8): 500-10.
- Huang W, Qiao Y, Tang X Robust scene text detection with convolution neural network induced mserr trees. pp. 497-511; pp. 497-511. *Springer*.

- Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac Radiol.* 2020; 49(1): 20190107.
- Hyun CM, Bayarara T, Yun HS, Jang TJ, Park HS, Seo JK. Deep learning method for reducing metal artifacts in dental cone-beam CT using supplementary information from intra-oral scan. *Phys Med Biol.* 2022; 67(17).
- İpek S. Yapay zekanın toplum üzerindeki etkisi ve yapay zekâ (AI) filmi bağlamında yapay zekaya bakış. *Uluslararası Ders Kitapları ve Eğitim Materyalleri Dergisi.* 2019; 2(2): 203-15.
- Jamtsho Y, Riyamongkol P, Waranusast R. Real-time Bhutanese license plate localization using YOLO. *ICT Express.* 2020; 6(2): 121-4.
- Jeoun BS, Yang S, Lee SJ et al. Canal-Net for automatic and robust 3D segmentation of mandibular canals in CBCT images using a continuity-aware contextual network. *Sci Rep.* 2022; 12(1): 13460.
- Jiang F, Jiang Y, Zhi H et al. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol.* 2017; 2(4): 230-43.
- Jiang L, Chen D, Cao Z, Wu F, Zhu H, Zhu F. A two-stage deep learning architecture for radiographic staging of periodontal bone loss. *BMC Oral Health.* 2022; 22(1): 106.
- Jiang P, Ergu D, Liu F, Cai Y, Ma B. A Review of Yolo Algorithm Developments. *Procedia Computer Science.* 2022; 199: 1066-73.
- Jiang Y, Yang M, Wang S, Li X, Sun Y. Emerging role of deep learning-based artificial intelligence in tumor pathology. *Cancer Commun (Lond).* 2020; 40(4): 154-66.
- John H. Holland. genetic algorithms. *Scientific American.* 1992; 267(1): 44-50.
- Kabalıcı E (2014) Yapay Sinir Ağları. Ders Notları.
- Kamble RM, Chan GCY, Perdomo O et al. Automated Diabetic Macular Edema (DME) Analysis using Fine Tuning with Inception-Resnet-v2 on OCT Images. pp. 442-6; pp. 442-6.
- Kamburoğlu K, Kolsuz E, Murat S, Yüksel S, Özen T. Proximal caries detection accuracy using intraoral bitewing radiography, extraoral bitewing radiography and panoramic radiography. *Dentomaxillofac Radiology.* 2012; 41(6): 450-9.
- Kang K, Ouyang W, Li H, Wang X Object detection from video tubelets with convolutional neural networks. pp. 817-25; pp. 817-25.
- Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. *Gastrointestinal endoscopy.* 2020; 92(4): 807-12.
- Kaya E, Güneç HG, Ürkmez E, Cesur Aydın K, Ateş HF. Deep Learning for Diagnostic Charting on Pediatric Panoramic Radiographs. *Int J Comput Dent.* 2023; 0(0): 0.
- Keser G, Bayrakdar İ, Pekiner FN, Çelik Ö, Orhan K. A deep learning algorithm for classification of oral lichen planus lesions from photographic images: A retrospective study. *J Stomatol Oral Maxillofac Surg.* 2023; 124(1): 101264.
- Keskenler MF, Keskenler EF. Bulanık mantığın tarihi gelişimi. *Takvim-i Vekayi.* 2017; 5(1): 1-10.
- Kidd EA, Fejerskov O. What constitutes dental caries? Histopathology of carious enamel and dentin related to the action of cariogenic biofilms. *J Dent Res.* 2004; 83: C35-8.
- Kidd EA, Pitts NB. A reappraisal of the value of the bitewing radiograph in the diagnosis of posterior approximal caries. *Br Dent J.* 1990; 169(7): 195-200.
- Kidd Edwina A (2005) Essentials of dental caries: The disease and its management. Oxford USA: Oxford University Press.
- Kılınç D, Başeğmez N. Uygulamalarla veri bilimi yapay zeka ve makine öğrenmesi (3. Baskı). İstanbul: Abaküs. 2019.
- Kim H, Shim E, Park J, Kim YJ, Lee U, Kim Y. Web-based fully automated cephalometric analysis by deep learning. *Comput Methods Programs Biomed.* 2020; 194: 105513.
- Kim JH, Kim N, Won CS High-Speed Drone Detection Based On Yolo-V8. pp. 1-2; pp. 1-2.

- Kirişçi M. Comparison of artificial neural network and logistic regression model for factors affecting birth weight. *SN Applied Sciences*. 2019; 1.
- Kise Y, Shimizu M, Ikeda H et al. Usefulness of a deep learning system for diagnosing Sjögren's syndrome using ultrasonography images. *Dentomaxillofac Radiol*. 2020; 49(3): 20190348.
- Koçoğlu F, Özcan T (2018) Dengeli- Dengesiz Veri Seti Dağılımının Aşırı Öğrenme Makinesi Yöntemi Performansına Etkisi.
- Kohavi R. Glossary of terms. Special issue on applications of machine learning the knowledge discovery process. 1998; 30(271): 127-32.
- Korkut B, Taştekin DA, Yanıkoğlu F. Diş çürüklerinin erken teşhisi ve teşhiste yeni yöntemler: QLF, Diagnodent, Elektriksel İletkenlik ve Ultrasonik Sistem. *Ege Üniversitesi Diş Hekimliği Fakültesi Dergisi*. 2011; 32(2): 55-67.
- Krenker A, Beşter J, Kos A. Introduction to the artificial neural networks. *Artificial Neural Networks: Methodological Advances Biomedical Applications*. 2011: 1-18.
- Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Communications of the ACM*. 2017; 60(6): 84-90.
- Kuipers B, Feigenbaum EA, Hart PE, Nilsson NJ. Shakey: From Conception to History. *AI Magazine*. 2017; 38(1): 88-103.
- Kulikowski CA. An Opening Chapter of the First Generation of Artificial Intelligence in Medicine: The First Rutgers AIM Workshop, June 1975. *Yearb Med Inform*. 2015; 10(1): 227-33.
- Kulikowski CA. Beginnings of Artificial Intelligence in Medicine (AIM): Computational Artifice Assisting Scientific Inquiry and Clinical Art - with Reflections on Present AIM Challenges. *Yearb Med Inform*. 2019; 28(1): 249-56.
- Kunhimangalam R, Ovalath S, Joseph PK. A clinical decision support system with an integrated EMR for diagnosis of peripheral neuropathy. *Journal of Medical Systems*. 2014; 38: 1-14.
- Kurt M, Kurt Z, Işık Ş. Using deep learning approaches for coloring silicone maxillofacial prostheses: A comparison of two approaches. *J Indian Prosthodont Soc*. 2023; 23(1): 84-9.
- Kurzweil R, Richter R, Kurzweil R, Schneider ML (1990) *The age of intelligent machines*: MIT press Cambridge.
- Kühnisch J, Meyer O, Hesenius M, Hickel R, Gruhn V. Caries Detection on Intraoral Images Using Artificial Intelligence. *J Dent Res*. 2022; 101(2): 158-65.
- Lacruz RS, Habelitz S, Wright JT, Paine ML. Dental Enamel Formation and Implications for Oral Health and Disease. *Physiol Rev*. 2017; 97(3): 939-93.
- Lampen N, Kim D, Fang X et al. Deep learning for biomechanical modeling of facial tissue deformation in orthognathic surgical planning. *Int J Comput Assist Radiol Surg*. 2022; 17(5): 945-52.
- Landis JR, Koch GG. An application of hierarchical kappa-type statistics in the assessment of majority agreement among multiple observers. *Biometrics*. 1977: 363-74.
- Langlais RP, Skoczylas LJ, Prihoda TJ, Langland OE, Schiff T. Interpretation of bitewing radiographs: application of the kappa statistic to determine rater agreements. *Oral Surgery, Oral Medicine, Oral Pathology*. 1987; 64(6): 751-6.
- LeCun Y, Bengio Y, Hinton G. Deep learning. *nature*, 521 (7553), 436-444. 2015.
- LeCun Y, Boser B, Denker J et al. Handwritten digit recognition with a back-propagation network. *Advances in neural information processing systems*. 1989; 2.
- LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 1998; 86(11): 2278-324.
- Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent*. 2018; 77: 106-11.
- Lee S, Oh SI, Jo J, Kang S, Shin Y, Park JW. Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep*. 2021; 11(1): 16807.

- Lee SC, Hwang HS, Lee KC. Accuracy of deep learning-based integrated tooth models by merging intraoral scans and CBCT scans for 3D evaluation of root position during orthodontic treatment. *Prog Orthod.* 2022; 23(1): 15.
- LeGeros R (1991) 7. Calcium Phosphates in Dental Calculus and Dental Caries. *Calcium Phosphates in Oral Biology and Medicine*, pp. 130-53; Karger Publishers.
- Li G, Suo R, Zhao G et al. Real-time detection of kiwifruit flower and bud simultaneously in orchard using YOLOv4 for robotic pollination. *Computers Electronics in Agriculture.* 2022; 193: 106641.
- Lian L, Zhu T, Zhu F, Zhu H. Deep Learning for Caries Detection and Classification. *Diagnostics.* 2021; 11(9).
- Litjens G, Kooi T, Bejnordi BE et al. A survey on deep learning in medical image analysis. *Medical image analysis.* 2017; 42: 60-88.
- Liu W, Anguelov D, Erhan D et al. Ssd: Single shot multibox detector. pp. 21-37; pp. 21-37. Springer.
- Liyanage H, Liaw ST, Jonnagaddala J et al. Artificial Intelligence in Primary Health Care: Perceptions, Issues, and Challenges. *Yearb Med Inform.* 2019; 28(1): 41-6.
- Lussi A. Comparison of different methods for the diagnosis of fissure caries without cavitation. *Caries Res.* 1993; 27(5): 409-16.
- Machoy ME, Szyszka-Sommerfeld L, Vegh A, Gedrange T, Woźniak K. The ways of using machine learning in dentistry. *Adv Clin Exp Med.* 2020; 29(3): 375-84.
- Maity M, Banerjee S, Chaudhuri SS Faster R-CNN and YOLO based Vehicle detection: A Survey. pp. 1442-7; pp. 1442-7.
- Maizels M, Wolfe WJ. An expert system for headache diagnosis: the Computerized Headache Assessment tool (CHAT). *Headache: The Journal of Head Face Pain.* 2008; 48(1): 72-8.
- Malik H, Srivastava S, Sood YR, Ahmad A. Applications of artificial intelligence techniques in engineering. *Sigma.* 2018; 1.
- Malik P, Pathania M, Rathaur VK. Overview of artificial intelligence in medicine. *Journal of family medicine primary care.* 2019; 8(7): 2328.
- Man KF, Tang KS, Kwong S (2001) *Genetic algorithms: concepts and designs*: Springer Science & Business Media.
- Mannila H Data mining: machine learning, statistics, and databases. pp. 2-9; pp. 2-9.
- Mao YC, Chen TY, Chou HS et al. Caries and Restoration Detection Using Bitewing Film Based on Transfer Learning with CNNs. *Sensors.* 2021; 21(13).
- Marchais P De l'esprit et des modes de classification en psychiatrie. pp. 247-52; pp. 247-52. Elsevier.
- Markoff J. Scientists see promise in deep-learning programs, ny times. <http://nyti.ms/sgcVec>. 2012.
- Martinez-Franco AI, Sanchez-Mendiola M, Mazon-Ramirez JJ et al. Diagnostic accuracy in Family Medicine residents using a clinical decision support system (DXplain): a randomized-controlled trial. *Diagnosis.* 2018; 5(2): 71-6.
- Matalon S, Feuerstein O, Kaffe I. Diagnosis of approximal caries: bite-wing radiology versus the Ultrasound Caries Detector. An in vitro study. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, Endodontology.* 2003; 95(5): 626-31.
- McCarthy J. From here to human-level AI. *Artificial Intelligence.* 2007; 171(18): 1174-82.
- McComb D, Tam LE. Diagnosis of occlusal caries: Part I. Conventional methods. *J Can Dent Assoc.* 2001; 67(8): 454-7.
- McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bull Math Biol.* 1990; 52(1-2): 99-115; discussion 73-97.
- Mikolov T, Karafiát M, Burget L, Cernocký J, Khudanpur S Recurrent neural network based language model. pp. 1045-8; pp. 1045-8.

- Miladinović M, Mihailović B, Mladenović D et al. Artificial intelligence in clinical medicine and dentistry. *Vojnosanitetski pregled*. 2017; 74(3): 267-72.
- Mjör IA, Toffenetti F. Secondary caries: a literature review with case reports. *Quintessence Int*. 2000; 31(3): 165-79.
- Moran ME. Evolution of robotic arms. *J Robot Surg*. 2007; 1(2): 103-11.
- Mortensen D, Ekstrand KR, Twetman S. Detection of occlusal caries with impedance spectroscopy and laser fluorescence before and after placement of fissure sealants: An in vitro study. *Am J Dent*. 2016; 29(4): 229-33.
- Nabiyev VV (2012) Yapay zeka: insan-bilgisayar etkileşimi: Seçkin Yayıncılık.
- Nanci A. Enamel: composition, formation, and structure. Ten Cate's oral histology development, structure, function. 2008: 141-90.
- Naranjo CA, Bremner KE, Bazoon M, Turksen IB. Using fuzzy logic to predict response to citalopram in alcohol dependence. *Clinical Pharmacology Therapeutics*. 1997; 62(2): 209-24.
- Newman ME, Friedman S. Extraoral radiographic technique: an alternative approach. *J Endod*. 2003; 29(6): 419-21.
- Ni L, Lu C, Liu N, Liu J Mandy: Towards a smart primary care chatbot application. pp. 38-52; pp. 38-52. Springer.
- Nilsson NJ, Nilsson NJ (1998) Artificial intelligence: a new synthesis: Morgan Kaufmann.
- O'Shea K, Nash R. An introduction to convolutional neural networks. *arXiv preprint*. 2015: 08458.
- Ogawa K, Yamashita Y, Ichijo T, Fusayama T. The ultrastructure and hardness of the transparent of human carious dentin. *J Dent Res*. 1983; 62(1): 7-10.
- Olshausen BA, Field DJ. Wavelet-like receptive fields emerge from a network that learns sparse codes for natural images. *Nature*. 1996; 381: 607-9.
- Ongsulee P Artificial intelligence, machine learning and deep learning. pp. 1-6; pp. 1-6. IEEE.
- Oshita S, Nakakimura K, Sakabe T. Hypertension control during anesthesia. Fuzzy logic regulation of nicardipine infusion. *IEEE Engineering in Medicine Biology Magazine*. 1994; 13(5): 667-70.
- Ouyang W, Wang X Joint deep learning for pedestrian detection. pp. 2056-63; pp. 2056-63.
- Özbaysar E, Borandağ E Vehicle plate tracking system. pp. 1-4; pp. 1-4. IEEE.
- Öznur İ, Korukoğlu SJYvED. Genetik algoritma yaklaşımı ve yöneylem araştırmasında bir uygulama. 2003; 10(2): 191-208.
- Öztemel E (2006) Yapay sinir ağları: Papatya.
- Öztemel E (2012) Yapay sinir ağları: Papatya.
- Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*. 2018; 6(2): 25-36.
- Öztürk K, Şahin M. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. 2018; 6(2): 25-36.
- Padilla R, Netto SL, Da Silva EA A survey on performance metrics for object-detection algorithms. pp. 237-42; pp. 237-42. IEEE.
- Paikar D. YOLO-Based Lung Segmentation for Medical Imaging Analysis. 2013.
- Pandl KD, Thiebes S, Schmidt-Kraepelin M, Sunyaev AJIa. On the convergence of artificial intelligence and distributed ledger technology: A scoping review and future research agenda. 2020; 8: 57075-95.
- Pannala R, Krishnan K, Melson J et al. Artificial intelligence in gastrointestinal endoscopy. *VideoGIE*. 2020; 5(12): 598-613.
- Panyarak W, Suttapak W, Wantanajittikul K, Charuakkra A, Prapayasatok S. Assessment of YOLOv3 for caries detection in bitewing radiographs based on the ICCMS™ radiographic scoring system. *Clin Oral Investig*. 2023; 27(4): 1731-42.
- Papageorgiou EI, Stylios CD, Groumpos PP. An integrated two-level hierarchical system for decision making in radiation therapy based on fuzzy cognitive maps. *IEEE transactions on Biomedical Engineering*. 2003; 50(12): 1326-39.

- Parunak HVD. Applications of distributed artificial intelligence in industry. *Foundations of distributed artificial intelligence*. 1996; 2(1): 18.
- Patil DD, Deore SG. Medical image segmentation: a review. *International Journal of Computer Science Mobile Computing*. 2013; 2(1): 22-7.
- Pedrosa RF, Brasileiro I, dos Anjos Pontual M, dos Anjos Pontual A, da Silveira M. Influence of materials radiopacity in the radiographic diagnosis of secondary caries: evaluation in film and two digital systems. *Dentomaxillofacial Radiology*. 2011; 40(6): 344-50.
- Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *European radiology experimental*. 2018; 2: 1-10.
- Pitts NB. Diagnostic tools and measurements-impact on appropriate care. *Community Dentistry Oral Epidemiology*. 1997; 25(1): 24-35.
- Pitts NB. Are we ready to move from operative to non-operative/preventive treatment of dental caries in clinical practice? *Caries Res*. 2004; 38(3): 294-304.
- Poole D, Mackworth A, Goebel R. *Computational intelligence: a logical approach*. (1998). Radiation UNSCotEoA (1988) Report: United Nations.
- Rath S (2023) [WWW document]. <https://learnopencv.com/ultralytics-yolov8/> URL| [accessed on.]
- Redmon J, Divvala S, Girshick R, Farhadi A You only look once: Unified, real-time object detection. pp. 779-88; pp. 779-88.
- Redmon J, Farhadi A. Yolo9000: better, faster, stronger *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017: 7263-71.
- Ren S, He K, Girshick R, Sun J. Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*. 2015; 28.
- Rich E, Knight K. *Artificial Intelligence* McGraw-Hill. 1991.
- Ritter AV (2017) *Sturdevant's art & science of operative dentistry-e-book*: Elsevier Health Sciences.
- Robinson C, Shore RC, Brookes SJ, Strafford S, Wood SR, Kirkham J. The chemistry of enamel caries. *Crit Rev Oral Biol Med*. 2000; 11(4): 481-95.
- Rodrigues JA, Hug I, Diniz MB, Lussi A. Performance of fluorescence methods, radiographic examination and ICDAS II on occlusal surfaces in vitro. *Caries Res*. 2008; 42(4): 297-304.
- Rojas R (2013) *Neural networks: a systematic introduction*: Springer Science & Business Media.
- Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol Rev*. 1958; 65(6): 386-408.
- Roy AM, Bose R, Bhaduri J. A fast accurate fine-grain object detection model based on YOLOv4 deep neural network. *Neural Computing Applications*. 2022: 1-27.
- Russel J, Norvig P (2010) *Artificial Intelligence A Modern Approach*, 3. izdanje. New Jersey: Pearson Education, (dostupno na: <https://readyforai.com/download>
- Russell R (2020) *Machine Learning: Step-by-Step Guide To Implement Machine Learning Algorithms with Python*.
- Sağiroğlu Ş, Erler M, Beşdok E (2003) *Mühendislikte yapay zeka uygulamaları-I: yapay sinir ağları*.
- Salama FS, Al-Hammad NS. Marginal seal of sealant and compomer materials with and without enameloplasty. *Int J Paediatr Dent*. 2002; 12(1): 39-46.
- Sariel S. *Günümüzde yapay zeka*. İstanbul Teknik Üniversitesi Vakfı Dergisi. 2017.
- Say C (2018) *50 Soruda yapay zeka: Bilim ve Gelecek Kitaplığı*.
- Schmidt R, Gierl L. Case-based reasoning for antibiotics therapy advice: an investigation of retrieval algorithms and prototypes. *Artificial intelligence in Medicine*. 2001; 23(2): 171-86.
- Schneiderman A, Elbaum M, Shultz T, Keem S, Greenebaum M, Driller J. Assessment of dental caries with Digital Imaging Fiber-Optic Transillumination (DIFOTI): in vitro study. *Caries Res*. 1997; 31(2): 103-10.

- Schwendicke F, Frencken JE, Bjørndal L et al. Managing carious lesions: consensus recommendations on carious tissue removal. *Adv Dent Res.* 2016; 28(2): 58-67.
- Seker H, Odetayo MO, Petrovic D, Naguib RNG. A fuzzy logic based-method for prognostic decision making in breast and prostate cancers. *IEEE Transactions on Information Technology in Biomedicine.* 2003; 7(2): 114-22.
- Selwitz RH, Ismail AI, Pitts NB. Dental caries. *Lancet.* 2007; 369(9555): 51-9.
- Serhatlıoğlu S, Hardalaç F. Yapay zeka teknikleri ve radyolojiye uygulanması. *Fırat Tıp Dergisi.* 2009; 14(1): 1-6.
- Shabbir J, Anwer TJapa. Artificial intelligence and its role in near future. 2018.
- Shan T, Tay FR, Gu L. Application of Artificial Intelligence in Dentistry. *J Dent Res.* 2021; 100(3): 232-44.
- Shapiro SCJNJAWIP. Encyclopedia of artificial intelligence second edition. 1992.
- Sharaf-El-Deen DA, Moawad IF, Khalifa M. A new hybrid case-based reasoning approach for medical diagnosis systems. *Journal of Medical Systems.* 2014; 38: 1-11.
- Sheikhtaheri A, Sadoughi F, Hashemi Dehaghi Z. Developing and Using Expert Systems and Neural Networks in Medicine: A Review on Benefits and Challenges. *Journal of Medical Systems.* 2014; 38(9): 110.
- Shetty J, Jogi PS Study on different region-based object detection models applied to live video stream and images using deep learning. pp. 51-60; pp. 51-60. Springer.
- Shortliffe EH, Davis R, Axline SG, Buchanan BG, Green CC, Cohen SN. Computer-based consultations in clinical therapeutics: explanation and rule acquisition capabilities of the MYCIN system. *Comput Biomed Res.* 1975; 8(4): 303-20.
- Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv.* 2014.
- Solawetz J, Francesco (2023) What is YOLOv8? The Ultimate Guide. [WWW document]. <https://blog.roboflow.com/whats-new-in-yolov8/> URL| [accessed on 2023].
- Son DM, Yoon YA, Kwon HJ, Lee SH. Combined Deep Learning Techniques for Mandibular Fracture Diagnosis Assistance. *Life.* 2022; 12(11).
- Sonesson M, Bergstrand F, Gizani S, Twetman S. Management of post-orthodontic white spot lesions: an updated systematic review. *Eur J Orthod.* 2017; 39(2): 116-21.
- Song HA, Lee S-Y Hierarchical representation using NMF. pp. 466-73; pp. 466-73. Springer.
- Steimann F. On the use and usefulness of fuzzy sets in medical AI. *Artif Intell Med.* 2001; 21(1-3): 131-7.
- Stubbs DF Multiple neural network approaches to clinical expert systems. pp. 433-41; pp. 433-41.
- Sukegawa S, Tanaka F, Nakano K et al. Effective deep learning for oral exfoliative cytology classification. *Sci Rep.* 2022; 12(1): 13281.
- Szegedy C, Liu W, Jia Y et al. Going deeper with convolutions. pp. 1-9; pp. 1-9.
- Şen Z (2004) Yapay sinir ağları: Su Vakfı.
- Taigman Y, Yang M, Ranzato MA, Wolf L Deepface: Closing the gap to human-level performance in face verification. pp. 1701-8; pp. 1701-8.
- Takahashi N, Nyvad B. Ecological Hypothesis of Dentin and Root Caries. *Caries Res.* 2016; 50(4): 422-31.
- Takebe K, Imai T, Kubota S, Nishimoto A, Amekawa S, Uzawa N. Deep learning model for the automated evaluation of contact between the lower third molar and inferior alveolar nerve on panoramic radiography. *J Dent Sci.* 2023; 18(3): 991-6.
- Tan FG, Yüksel AS, Aydemir E, Ersoy M. Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme. *Avrupa Bilim ve Teknoloji Dergisi.* 2021; (25): 159-71.
- Tang Y, Salakhutdinov R, Hinton G Robust boltzmann machines for recognition and denoising. pp. 2264-71; pp. 2264-71.

- Terry GL, Noujeim M, Langlais RP, Moore WS, Prihoda TJ. A clinical comparison of extraoral panoramic and intraoral radiographic modalities for detecting proximal caries and visualizing open posterior interproximal contacts. *Dentomaxillofacial Radiology*. 2016; 45(4): 20150159.
- Tetschke F, Golde J, Rosenauer T et al. Correlation between Lesion Progression and Depolarization Assessed by Polarization-Sensitive Optical Coherence Tomography. *Applied Sciences*. 2020; 10(8): 2971.
- Ting DSW, Peng L, Varadarajan AV et al. Deep learning in ophthalmology: The technical and clinical considerations. *Prog Retin Eye Res*. 2019; 72: 100759.
- Tran KA, Kondrashova O, Bradley A, Williams ED, Pearson JV, Waddell N. Deep learning in cancer diagnosis, prognosis and treatment selection. *Genome Med*. 2021; 13(1): 152.
- Tuzcuoglu H. Yapay Zeka Teknikleri, Depremde Kullanılması ve Küme Kuramları. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*. 2003; 5(1): 73-88.
- Tyas MJ, Anusavice KJ, Frencken JE, Mount GJ. Minimal intervention dentistry--a review. FDI Commission Project 1-97. *Int Dent J*. 2000; 50(1): 1-12.
- Uzun H, Nazlıel CH. Yaşlıda medikal ve dental hikâye ile ekstraoral, intraoral ve dental muayene bulguları. *Geriatric Dergisi*. 2000; 3(1): 15-21.
- Uzun Saylan BC, Baydar O, Yeşilova E et al. Assessing the Effectiveness of Artificial Intelligence Models for Detecting Alveolar Bone Loss in Periodontal Disease: A Panoramic Radiograph Study. *Diagnostics*. 2023; 13(10).
- Vaarkamp J, Ten Bosch JJ, Verdonchot EH, Bronkhorst EM. The Real Performance of Bitewing Radiography and Fiber-Optic Transillumination in Approximal Caries Diagnosis. *J Dent Res*. 2000; 79(10): 1747-51.
- Van Dorp CS, Exterkate RA, ten Cate JM. The effect of dental probing on subsequent enamel demineralization. *ASDC J Dent Child*. 1988; 55(5): 343-7.
- Wang C-Y, Bochkovskiy A, Liao H-YM. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022: 7464-75.
- Wei M, Zhou Z. Ai ethics issues in real world: Evidence from ai incident database. *arXiv*. 2022: 07635.
- Weiss S, Kulikowski CA, Safir A. Glaucoma consultation by computer. *Comput Biol Med*. 1978; 8(1): 25-40.
- Weizenbaum J. ELIZA—a computer program for the study of natural language communication between man and machine. 1966; 9(1 %J Commun. ACM): 36–45.
- Wernick MN, Yang Y, Brankov JG, Yourganov G, Strother SC. Machine learning in medical imaging. *IEEE signal processing magazine*. 2010; 27(4): 25-38.
- White SC, Pharoah MJ (2014) *Oral radiology-E-Book: Principles and interpretation*: Elsevier Health Sciences.
- Winston PH (1992) *Artificial intelligence*: Addison-Wesley Longman Publishing Co., Inc.
- Xiao Y, Tian Z, Yu J et al. A review of object detection based on deep learning. *Multimedia Tools and Applications*. 2020; 79(33): 23729-91.
- Yan B, Li J, Yang Z, Zhang X, Hao X. AIE-YOLO: Auxiliary Information Enhanced YOLO for Small Object Detection. *Sensors (Basel)*. 2022; 22(21).
- Yan R, Fan C, Yin Z, Wang T, Chen X. Potential applications of deep learning in single-cell RNA sequencing analysis for cell therapy and regenerative medicine. *Stem Cells*. 2021; 39(5): 511-21.
- Yang S, Lee H, Jang B et al. Development and Validation of a Visually Explainable Deep Learning Model for Classification of C-shaped Canals of the Mandibular Second Molars in Periapical and Panoramic Dental Radiographs. *J Endod*. 2022; 48(7): 914-21.
- Yıkılğan İ, Kılıç H. Dental Caries and Dental Hard Tissues. *Türkiye Klinikleri J Restor Dent Special Topics*. 2016; 2(1): 5-8.

- Yılmaz A, Kaya U (2021) Derin öğrenme: Kodlab.
- Yuce F, Öziç M, Tassoker M. Detection of pulpal calcifications on bite-wing radiographs using deep learning. Clin Oral Investig. 2022.
- Yung NDT, Wong WK, Juwono FH, Sim ZA Safety Helmet Detection Using Deep Learning: Implementation and Comparative Study Using YOLOv5, YOLOv6, and YOLOv7. pp. 164-70; pp. 164-70.
- Zeiler MD, Fergus R Visualizing and understanding convolutional networks. pp. 818-33; pp. 818-33. Springer.
- Zhang B, Xiong D, Su J. Cyclic sequence-to-sequence learning. arXiv. 2016.
- Zhu H, Cao Z, Lian L, Ye G, Gao H, Wu J. CariesNet: a deep learning approach for segmentation of multi-stage caries lesion from oral panoramic X-ray image. Neural Comput Appl. 2022: 1-9.
- Zrimec T, Kononenko I. Feasibility analysis of machine learning in medical diagnosis from aura images. Сознание и физическая реальность. 1999; 4(4): 66-72.



## **8. ÖZGEÇMİŞ**



## **9. EKLER**

Ek-A



T.C.

NECMETTİN ERBAKAN ÜNİVERSİTESİ DIŞ HEKİMLİĞİ  
İLAÇ VE TIBBİ CİHAZ DIŞI ARAŞTIRMALAR ETİK KURULU

Toplantı Sayısı: 19

Toplantı Tarihi: 30.06.2022

Karar Sayısı:2022/150.(Başvuru ID: 10495) N.E.Ü. Diş Hekimliği Fakültesi Klinik Bilimler Bölümü Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Öğretim Üyesi Doç. Dr. Melek TAŞSÖKER'in "Bite-wing Radyografilerde Interproksimal, Oklüzal ve Sekonder Çürüklerin Yapay Zeka ile Otomatik Tespiti: Klinik Kullanım İçin Arayüz Tasarımı" başlıklı uzmanlık tez çalışması ile ilgili başvurusu görüşüldü. Arş. Gör. Rabia KARAKUŞ'un uzmanlık tez çalışmasının, N.E.Ü. Diş Hekimliği Fakültesi Klinik Bilimler Bölümü Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Öğretim Üyesi Doç. Dr. Melek TAŞSÖKER'in sorumluluğunda yürütülmesinin uygun olduğuna oybirliği ile karar verilmiştir.

Not: Çalışma ile ilgili gerekli izin ve yasal sorumluluk araştırmacıya aittir.

Sorumlu Araştırmacı: Doç. Dr. Melek TAŞSÖKER

Yardımcı Araştırmacılar: Arş. Gör. Rabia KARAKUŞ-Dr. Öğr. Üyesi Muhammet Ösane ÖZİÇ

Prof. Dr. Bozkurt Kubilay IŞIK  
Etik Kurulu Başkanı