

T.C.  
AKDENİZ ÜNİVERSİTESİ  
DİŞ HEKİMLİĞİ FAKÜLTESİ  
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

DENTAL İMPLANTLARIN MARKA VE MODEL  
TANIMLAMASINDA YAPAY ZEKA SİSTEMLERİ  
ETKİNLİĞİNİN DEĞERLENDİRİLMESİ

Dt. Tarık Ali UĞUR

DİŞ HEKİMLİĞİNDE UZMANLIK TEZİ

DANIŞMAN  
Doç. Dr. Selmi YARDIMCI

2023-ANTALYA

## ONAY SAYFASI

Tarık Ali UĞUR tarafından sunulan bu çalışma jürimiz tarafından **oy birliği/oy çokluğu** ile Ağız, Diş ve Çene Radyolojisi Anabilim Dalında Uzmanlık Tezi olarak kabul edilmiştir. .../...../.....

**İmza**

**Üye** : .....  
(Ünvanı, Adı Soyadı) (Üniversite)

**Üye** : .....  
(Ünvanı, Adı Soyadı) (Üniversite)

**Üye** : .....  
(Ünvanı, Adı Soyadı) (Üniversite)

Bu tez, ...../...../..... tarih ve ...../..... sayılı Yönetim Kurulu kararıyla belirlenen ve yukarıda imzaları bulunan jüri üyeleri tarafından kabul edilmiştir.

**Diş Hekimliği Fakültesi**

**Kurum Yöneticisi**

## ETİK BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı beyan ederim.

Aday

**Tarık Ali UĞUR**

İmza

Tez Danışmanı

**Doç. Dr. Selmi YARDIMCI**

İmza

## TEŞEKKÜRLER

Uzmanlık eğitimim boyunca bana destek olup engin bilgi ve deneyimlerini benimle paylaşan, sabrı ve fedakarlığıyla eğitimime destek olan, pek kıymetli danışman hocam Doç. Dr. Selmi YARDIMCI'ya,

Verdiği emekler ve aktardığı tecrübeleriyle uzmanlık eğitimim sürecinde her zaman destek olan hocalarım Doç. Dr. Sevcihan GÜNEN YILMAZ ve Doç. Dr. Hümeysra TERCANLI'ya,

Uzmanlık eğitimini beraber sürdürdüğümüz, tanışmaktan ve beraber çalışmaktan onur duyduğum araştırma görevlisi arkadaşlarıma,

Benim için çalışma koşullarımızı güzelleştiren değerli Anabilim Dalı'mızın personellerine,

Har daim yanımda olan ve hiçbir zaman desteklerini esirgemeyen aileme,

Şükranlarımı sunmayı borç bilirim.

## ÖZET

**Amaç:** Dental implantlar, eksik dişler için en popüler ve kabul gören rehabilitasyon yöntemlerinden biri haline gelmiştir. Birçok parça içeren dental implantlar, kendine has tasarıma sahiptir ve diş hekimlerinin etkin bir tedavi sunabilmesi için implantların üreticisini tanımlayabilmesi gerekir. Çalışmamızın amacı, yapay zeka sistemlerinin çeşitli dental implantların marka ve modelini tanımlamadaki etkinliğini değerlendirmektir.

**Yöntem:** Bu çalışmada, 2020 - 2023 arası Akdeniz Üniversitesi Diş Hekimliği Fakültesi'nde dental implant tedavisi uygulanmış hastalardan alınan panoramik radyograflar geriye dönük olarak toplanmıştır. Beş üreticinin yedi implant modeline ait 1907 adet implant içeren toplam 523 panoramik radyograf veri setine dahil edilmiştir. Bu veri setine parlaklık ve rotasyon değişiklikleri yapılarak veri artırma uygulanmıştır. Elde edilen yeni veri setinin %80'i eğitim, %10'u doğrulama ve %10'u test verisi olarak bölünmüş ve implantların etiketlenmesi LabelImg programı kullanılarak yapılmıştır. İmplant sistemlerinin tanımlanması amacıyla yapay zeka tabanlı nesne tespit yöntemlerinden YOLOv5, YOLOv7 ve YOLOv8 algoritmaları kullanılmıştır. Algoritmaların performansını değerlendirmek için kesinlik, duyarlılık, mAP, F1 skorları ve hata matrisleri kullanılmıştır.

**Bulgular:** Tüm implantlar arası kesinlik, duyarlılık, mAP ve F1 skorları YOLOv5 için sırasıyla 0,786, 0,648, 0,764 ve 0,71; YOLOv7 için sırasıyla 0,81, 0,815, 0,855 ve 0,81; YOLOv8 için 0,89, 0,901, 0,955 ve 0,89'dur. Algoritmalar veri setindeki sayısı fazla olan ve tasarımı farklı implantlarda genellikle daha iyi performans göstermiştir.

**Sonuç:** Yapay zeka tabanlı nesne tespit algoritmaları, nispeten küçük bir veri setinde bile, dental implantları panoramik radyograflar üzerinden tanımlamada yeterli bir performans göstermiştir. Algoritmalar güncellendikçe performansları giderek artmıştır. Daha büyük veri kümeleri ve farklı dental implantlarla eğitilmiş yapay zeka sistemleri, implantları tanımlamada hekimlere yardımcı olabilir.

**Anahtar Kelimeler:** yapay zeka, dental implant, nesne tespiti, panoramik radyografi

## ABSTRACT

**Objective:** Dental implants have become one of the most popular and accepted rehabilitation methods for missing teeth. Dental implants, which contain many parts, have a unique design and dentists need to be able to identify the manufacturer of the implants in order to provide effective treatment. The aim of our study is to evaluate the effectiveness of artificial intelligence systems in identifying the make and model of various dental implants.

**Method:** In this study, panoramic radiographs from patients who underwent dental implant treatment at Akdeniz University Faculty of Dentistry between 2020 and 2023 were retrospectively collected. A total of 523 panoramic radiographs including 1907 implants from seven implant models of five manufacturers were included in the dataset. Data augmentation was applied to this dataset with brightness and rotation modifications. The new dataset was divided into 80% training, 10% validation and 10% test data, and the implants were labeled using the LabelImg program. YOLOv5, YOLOv7 and YOLOv8 algorithms, which are artificial intelligence based object detection methods, were used to identify the implant systems. Precision, sensitivity, mAP, F1 scores and confusion matrices were used to evaluate the performance of the algorithms.

**Results:** The precision, recall, mAP and F1 scores across all implants were 0.786, 0.648, 0.764 and 0.71 for YOLO v5; 0.81, 0.815, 0.855 and 0.81 for YOLO v7; and 0.89, 0.901, 0.955 and 0.89 for YOLOv8, respectively. The algorithms generally performed better for implants with a larger number in the dataset and different implant designs.

**Conclusion:** Artificial Intelligence based object detection algorithms have performed adequately in identifying dental implants on panoramic radiographs, even on a relatively small dataset. As the algorithms were updated, their performance gradually improved. Artificial intelligence systems trained with larger datasets and different dental implants could help physicians to identify implants.

**Key words:** artificial intelligence, dental implant, object detection, panoramic radiography

## İÇİNDEKİLER

|                                                          |      |
|----------------------------------------------------------|------|
| ÖZET                                                     | i    |
| ABSTRACT                                                 | ii   |
| İÇİNDEKİLER                                              | iii  |
| SİMGELER VE KISALTMALAR                                  | iv   |
| ŞEKİLLER DİZİNİ                                          | vi   |
| TABLolar                                                 | viii |
| 1. GİRİŞ                                                 | 1    |
| 2. GENEL BİLGİLER                                        | 2    |
| 2.1. Dental İmplant                                      | 2    |
| 2.1.1. Dental İmplant Nedir?                             | 2    |
| 2.1.2. Dental İmplantın Kısa Tarihçesi                   | 2    |
| 2.1.3. Dental İmplantların Sınıflandırılması             | 4    |
| 2.1.4. İmplant Görüntüleme Yöntemleri                    | 8    |
| 2.2. Yapay Zeka                                          | 11   |
| 2.2.1. Yapay Zeka Nedir?                                 | 11   |
| 2.2.2. Yapay Zeka Tarihçesi                              | 11   |
| 2.2.3. Yapay Zeka Çeşitleri                              | 14   |
| 2.2.4. Diş Hekimliğinde Yapay Zeka Uygulamaları          | 26   |
| 3. GEREÇ VE YÖNTEM                                       | 31   |
| 3.1. Görüntülerin toplanması                             | 31   |
| 3.2. Veri Setlerinin Oluşturulması                       | 32   |
| 3.3. Görüntülerin etiketlenmesi                          | 33   |
| 3.4. Nesne Tespit Algoritmaları                          | 34   |
| 3.5. Algoritma Performanslarının Değerlendirme Ölçütleri | 34   |
| 4. BULGULAR                                              | 39   |
| 5. TARTIŞMA                                              | 45   |
| 6. SONUÇ VE ÖNERİLER                                     | 51   |
| KAYNAKLAR                                                | 53   |
| EK – 1                                                   | 63   |

## SİMGELER VE KISALTMALAR

**YOLO** You Only Look Once

**YOLOv5** You Only Look Once versiyon 5

**YOLOv7** You Only Look Once versiyon 7

**YOLOv8** You Only Look Once versiyon 8

**AI** Artificial Intelligence

**CNN** Convolutional Neural Network (Konvolüsyonel Sinir Ağı)

**ReLU** Rectified Linear Unit (Düzleştirilmiş Doğrusal Birim)

**mA** Miliamper

**kVp** Pik Kilovoltaj

**MS COCO** Microsoft Common Objects in Context

**DP** Doğru Pozitif

**YP** Yanlış Pozitif

**DN** Doğru Negatif

**YN** Yanlış Negatif

**mAP** Mean Average Precision

**IoU** Intersection over Union

**ROC** Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)

**AUC** Area Under the Curve (Eğri Altındaki Alan)



## ŞEKİLLER DİZİNİ

|                                                                                                                                                                                                                                          |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 2.1.</b> Formiggini implantlarının şematik ve radyografik görüntüsü                                                                                                                                                             | 3  |
| <b>Şekil 2.2.</b> Köpek tibiasına yerleştirilmiş implantın çevresindeki yeni kemik formasyonunu gösteren radyografik görüntü                                                                                                             | 4  |
| <b>Şekil 2.3.</b> Radyografik özelliklerine göre implant sınıflaması                                                                                                                                                                     | 7  |
| <b>Şekil 2.4.</b> Dişsiz mandibulanın implant öncesi değerlendirmesi için alınmış panoramik görüntüde hastanın ağzında opak işaretleyicili (5 mm çapında metal küreler) radyografik stentlerde oluşan farklı miktarlardaki magnifikasyon | 9  |
| <b>Şekil 2.5.</b> Turing Testi                                                                                                                                                                                                           | 12 |
| <b>Şekil 2.6.</b> Perceptron yapısı                                                                                                                                                                                                      | 14 |
| <b>Şekil 2.7.</b> Yapay zekanın temel kavramları                                                                                                                                                                                         | 15 |
| <b>Şekil 2.8.</b> Makine öğrenmesi çeşitleri                                                                                                                                                                                             | 16 |
| <b>Şekil 2.9.</b> Konvolüsyon katmanında filtre ile yapılan konvolüsyon işlemine örnek                                                                                                                                                   | 19 |
| <b>Şekil 2.10.</b> Bir görüntü üzerinde gerçekleştirilen konvolüsyon işlemine örnek                                                                                                                                                      | 20 |
| <b>Şekil 2.11.</b> Havuzlama çeşitlerine örnekler                                                                                                                                                                                        | 21 |
| <b>Şekil 2.12.</b> Tam bağlı katman örneği                                                                                                                                                                                               | 22 |
| <b>Şekil 2.13.</b> Nesne tespitinin bileşenleri                                                                                                                                                                                          | 23 |
| <b>Şekil 2.14.</b> YOLO'nun çalışma mantığı ve vektör yapısı                                                                                                                                                                             | 25 |
| <b>Şekil 2.15.</b> Yapay zeka kullanılarak son 10 yılda yapılan diş hekimliği çalışmaları                                                                                                                                                | 27 |
| <b>Şekil 3.1.</b> Veri artırma ile oluşturulan görüntüye bir örnek: orijinal görüntü (üst), 640 x 640 boyutlarına küçültülmüş, 13° derece döndürme, %23 parlaklık artırma sonrası oluşturulmuş ve etiketlenmiş görüntü (alt)             | 32 |
| <b>Şekil 3.2.</b> Tespit edilmeye çalışılan implantların örnek radyografik görüntüleri                                                                                                                                                   | 33 |
| <b>Şekil 3.3.</b> LabelImg programında iki farklı implant sistemine ait YOLO formatında (siyah ok) etiketleme örneği                                                                                                                     | 34 |

|                                                                                                                                                |    |
|------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 3.4.</b> İmplant tespitinde gerçekleştirilen iş akışına ait diyagram                                                                  | 35 |
| <b>Şekil 3.5.</b> IoU (birleşim üzerinden kesişim)                                                                                             | 35 |
| <b>Şekil 3.6.</b> mAP hesaplama aşamaları                                                                                                      | 37 |
| <b>Şekil 4.1.</b> YOLO algoritmalarının implantları sınıflandırmada gösterdiği mAP değerleri                                                   | 40 |
| <b>Şekil 4.2.</b> YOLO algoritmalarının implantları sınıflandırmada alınan F1 skorları                                                         | 40 |
| <b>Şekil 4.3.</b> YOLOv5 algoritmasına ait hata matrisi                                                                                        | 41 |
| <b>Şekil 4.4.</b> YOLOv7 algoritmasına ait hata matrisi                                                                                        | 42 |
| <b>Şekil 4.5.</b> YOLOv8 algoritmasına ait hata matrisi                                                                                        | 43 |
| <b>Şekil 4.6.</b> YOLOv8 algoritmasında implant sistemi tahminine ait bir örnek görüntü (1b: Straumann Bone Level, 1t: Straumann Tissue Level) | 44 |

## TABLÖLAR

|                                                                                                                 |    |
|-----------------------------------------------------------------------------------------------------------------|----|
| <b>Tablo 2.1.</b> İmplant görüntüleme yöntemleri                                                                | 8  |
| <b>Tablo 2.2.</b> Yapay zeka kullanılarak yapılan dental implant tanımlama çalışmaları                          | 30 |
| <b>Tablo 3.1.</b> Çalışmadaki implant sistemlerine ait panoramik görüntü ve etiket sayısı                       | 33 |
| <b>Tablo 3.2.</b> Hata matrisi                                                                                  | 36 |
| <b>Tablo 4.1.</b> YOLO algoritmalarının implantları sınıflandırmada gösterdiği kesinlik ve duyarlılık değerleri | 39 |



## 1. GİRİŞ

Dental implantlar, doğal dişler çeşitli sebeplerle kaybedildiğinde yapay kuronları desteklemek için diş etinin altına cerrahi olarak yerleştirilmiş biouyumlu metal desteklerdir. Tarih boyunca eksik dişlerin rehabilitasyonu amaçlı çeşitli denemeler olsa da ideal uygulama formu 20.yüzyılın sonlarında bulunabilmiştir. O tarihten bu yana dental implantlar eksik dişlerin rehabilitasyonunda yaygın olarak kullanılan bir yöntem olmuş ve yüzlerce üretici bu piyasaya girmiştir.<sup>(1)</sup> İmplantlar, markaların birbirinden ayırt edilmesini zorlaştıran farklı şekillerde vida ve üst yapılara sahiptir.<sup>(2)</sup> Bu nedenle implant markasının doğru tanımlanması önemli bir klinik problemdir.

Panoramik radyograflar çene kemikleri ve dişler hakkında bilgileri tek bir görüntüde elde eder ve implant görüntülemesinde de kullanılır.<sup>(3)</sup> Fakat böylesi görüntüler üzerinden implant markalarının tespiti için çaba ve deneyim gerekir. Bu sorunun çözülmesi için otomatize edilmiş bir sistemin kullanılması faydalı olacaktır.

Yapay zeka, nörolojik süreçleri taklit eden makine tabanlı algoritmaları kullanır. Son yıllarda yapay zeka algoritmalarında, karmaşık verilerin otomatik olarak işlenmesi ve sınıflandırılması konusunda büyük ilerlemeler kaydedilmiştir.<sup>(4)</sup>

Özellikle yapay sinir ağı ve derin öğrenmenin modellerinden biri olan konvolüsyonel sinir ağları, tıbbi görüntülerin sınıflandırılması da dahil olmak üzere bilgisayarla görme yetenekleri sunmaktadır.<sup>(5)</sup> Yakın zamanda, dental radyograflardaki çeşitli lezyonları veya nesneleri tespit etmek veya sınıflandırmak için konvolüsyonel sinir ağları kullanan birçok çalışma yapılmıştır.<sup>(6)</sup> Aynı amaçla, dental implantları sınıflandırmaya yönelik çalışmalar da literatürde kendine yer bulmuştur.<sup>(7,8)</sup> Fakat bilgimiz ışığında bu çalışmalar sınırlı sayıdadır.

Bu tez çalışmasında, panoramik radyograflar üzerinden yapay zeka tabanlı nesne tespit algoritmaları olan YOLOv5, YOLOv7 ve YOLOv8 kullanılarak dental implantlar tanımlanmaya çalışılmıştır.

## 2. GENEL BİLGİLER

### 2.1. Dental İmplant

#### 2.1.1. Dental İmplant Nedir?

İmplant kelimesi etimolojik olarak; Latince “in” ‘içerisine’ ve “plantare” ‘ekmek, yerleştirmek’ anlamına gelen kelimelerin birleşiminden türetilmiştir.<sup>(9)</sup>

Modern diş hekimliğinin amacı, stomatognatik sistemin atrofisi, hastalığı veya travmasından bağımsız olarak hastayı normal işlevine, konuşmasına, sağlığına ve estetiğine kavuşturmadır. Bu nihai amaca yanıt olarak, dental implantlar; periodontal hastalık, travma veya başka nedenlerle dişini veya dişlerini kaybetmiş, genel ağız sağlığı iyi olan kişiler için ideal bir seçenektir. Dental implantlar, doğal dişlerin olmadığı yerlerde yapay bir krunu desteklemek için diş eti altına cerrahi olarak yerleştirilen biyouyumlu metal ankrajlardır.<sup>(1)</sup>

Dental implantlarla ilgili artan ihtiyaç ve kullanım, hastaların daha uzun süre yaşaması, yaşa bağlı diş kaybı, hastaların sosyal açıdan daha aktif ve estetik açıdan daha bilinçli olması, daha yüksek kısmi veya tam dişsizlik insidansı ve geleneksel protezlerdeki komplikasyonlar ile açıklanabilir.<sup>(10)</sup>

#### 2.1.2. Dental İmplantın Kısa Tarihçesi

Dental implantların tarihi, eksik dişlerin yerine insan çene kemiklerine oyulmuş deniz kabukları ve taşların yerleştirildiği antik Mısır'a kadar uzanır.<sup>(11,12)</sup> Aynı şekilde, Güney ve Kuzey Amerika ile Orta Asya ve Akdeniz bölgelerinde 2000 yıldan daha eski erken uygarlıklarda başlamakla beraber modern anlamdaki implantoloji birkaç yüzyıllık bir geçmişe sahiptir. Arkeolojik bulgular, bu uygarlıkların eksik dişlerin yerini oyulmuş taş, deniz kabukları, kemikler, çekilmiş dişler, ve altın alaşımları kullanarak rehabilite ettiklerini göstermiştir.<sup>(13,14)</sup> 1930'larda Honduras'ta yapılan arkeolojik kazılarda, kayıp üç alt kesici dişin soketine yerleştirilmiş halde üç parça deniz kabuğu bulunmuş ve bunlardan ikisinin çevresinde kompakt kemik oluşumu ile osseointegrasyon sağlandığı gözlemlenmiştir.<sup>(15)</sup>

1500'lerden yaklaşık 1800'lere kadar Avrupa'da, yoksullardan satın alınan veya kadavralardan çalınan dişler, insandan insana transplantasyon için kullanılmıştır.<sup>(15)</sup> Modern dental implantlara dair teknik, ilk kez Fransız diş hekimi Maggiolo tarafından tanımlanmıştır. Bu teknikte çekim soketine 18 ayarlık altın alaşımı yerleştirmiş sonrasında üst yapı olarak porselen kullanılmıştır.<sup>(13,16)</sup>


1913'te Greenfield, 24 karat altınla kaplanmış irido-platin yapıli silindirik bir yapay kökü hastanın çene kemiğinde uygun bir kavite oluşturarak implante etmiştir.<sup>(17)</sup> 1930'lara gelindiğinde Strock kardeşler krom, kobalt ve molibdenden oluşan Vitallium alaşımını ağız içinde başarılı şekilde uygulamıştır.<sup>(18)</sup> 1938'de Doktor P.B. Adams, hem içten hem de dıştan yivli olan, iyileşme başlığı bulunan silindirik bir endosseöz implantın patentini almıştır.<sup>(19)</sup> İlk subperiosteal implant 1940'lı yılların başında Dahl tarafından uygulanmış olsa da, popülerliğini 1940'lı yılların sonunda Gershkoff ve Goldberg ile birlikte kazanmıştır.<sup>(16)</sup> Subperiosteal implant tasarımı, 1950'li yıllarda Lew, Bausch ve Berman tarafından daha fazla araştırılmış ve detaylandırılmıştır.<sup>(18)</sup> Yine 1940'lı yıllarda Formiggini, İtalya'da düzenlenen bir konferansta, paslanmaz çelik veya tantalyumdan oluşan, kendi üzerine sarılı ve spiral yapıda, kemik içi implantı tanıtmıştır (Şekil 2.1).<sup>(13,20)</sup>



Şekil 2.1. Formiggini implantlarının şematik ve radyografik görüntüsü<sup>(20)</sup>

Per-Ingvar Branemark adlı İsveçli bir ortopedi cerrahı, 1950'li yıllarda osseointegrasyon terimini ortaya atmış ve doku ile entegre protez çalışmalarına başlamıştır. Köpekler üzerinde yaptığı deneylerde yumuşak ve sert dokularda reaksiyon oluşturmada uzun vadeli implant entegrasyonu sağlamıştır (Şekil 2.2).<sup>(21)</sup>

Bunu takiben 1965 yılında ilk kez dişsiz bir insan üzerinde titanyum implantlar uygulanmış ve 10 yıllık takibi yapılmıştır.<sup>(22)</sup> Başarı ile sonuçlanan prelinik uygulamalar sonrasında dental rehabilitasyon için farklı implant sistemleri klinik rutinde uygulanmaya başlanmıştır.



**Şekil 2.2.** Köpek tibiasına yerleştirilmiş implantın çevresindeki yeni kemik formasyonunu gösteren radyografik görüntü<sup>(21)</sup>

### **2.1.3. Dental İmplantların Sınıflandırılması**

Günümüzde dental implantlar çok çeşitli şekillerde sınıflandırılabilir. Örnek bir sınıflama aşağıda verilmiştir<sup>(23)</sup>:

- 1) Dokuya penetrasyonuna göre
- 2) İmplantın makroskopik tasarımına göre
  - a) Silindirik
  - b) Vida
  - c) Blade
  - d) Pinler
  - e) Endodontik sabitleyiciler
- 3) İmplant tasarımına veya gereken ameliyat sayısına göre
- 4) İmplantın yüzeyine göre
- 5) İmplant yüzey dokusu ve pürüzlülüğüne göre
- 6) İmplant yüzeyinin kimyasal bileşimine göre
- 7) İmplantın yüzey enerjisi ve yüküne göre
- 8) İmplant-abutment arayüzüne göre
- 9) İmplant üretiminde kullanılan malzemeye göre
- 10) Dokunun gösterdiği biyolojik tepkinin türüne göre

11) İmplantın uzunluğuna göre

12) İmplantın genişliğine göre

Makroskopik tasarım esas alındığında, günümüz pratiğinde en sık kullanılan implantlar vida tipindedir.

### **Vida Tipi İmplantların Karakteristik Özellikleri**

Çeşitli firmalara ait kemik içi implantlar, makroskopik tasarımı üzerinden tanımlanabilmesi için Sahiwal ve arkadaşları tarafından özelliklerine göre sınıflandırılmıştır.<sup>(24,25)</sup> Bu sınıflamaya göre implantlar koronal, orta-gövde ve apikal olmak üç hayali bölgeye ayrılıp makroskopik özellikleri belirlenmiştir. Sonrasında Kent Howell ve Nate Farley tarafından bu özellikler esas alınarak çeşitli marka ve modelde implantlara ait üç bölgenin radyografik görüntüleri bir veri tabanı olarak internet üzerinde hizmete girmiştir.<sup>(26)</sup> Buna göre implantlar;


- 1) Koronal
  - a) Abutment arayüzü
    - i) Eksternal
    - ii) İnternal
    - iii) Diğer
  - b) Flanj
    - i) Geniş
    - ii) Daralan
    - iii) Düz
  - c) Boyun
    - i) Apikal boyun
- 2) Orta-gövde
  - a) İmplant konikliği
    - i) Konik
    - ii) Konik apeks
    - iii) Düz
  - b) İmplant yivi
    - i) Yivli
    - ii) Yivsiz
  - c) Yiv tipi






- i) V-şeklinde yivli
- ii) Ters buttress
- iii) Kare şeklinde yivli
- iv) Yuvarlak yivli
- d) Orta-gövde oluşu





3) Apikal

- a) Apeks şekli
  - i) V-şeklinde apeks
  - ii) Kavisli apeks
  - iii) Düz apeks
- b) Açık apeks
- c) Delik şekli
  - i) Yuvarlak
  - ii) Oblong
- d) Apikal boşluk
- e) Apikal oluk

olarak kategorize edilmiştir (Şekil 2.3).

|                                                                                   |                                                                                   |                                                                                   |                                                                                   |  |
|-----------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|--|
| Koronal                                                                           | Dayanak Arayüzü                                                                   | Flanj                                                                             | Boyun                                                                             |  |
|                                                                                   | Eksternal                                                                         | Geniş                                                                             | Apikal Boyun                                                                      |  |
|                                                                                   |  |  |  |  |
|                                                                                   | Internal                                                                          | Daralan                                                                           |                                                                                   |  |
|                                                                                   |  |  |                                                                                   |  |
|                                                                                   | Diğer                                                                             | Düz                                                                               |                                                                                   |  |
|  |  |                                                                                   |                                                                                   |  |

|                                                                                     |                                                                                    |                                                                                     |                                                                                    |                  |
|-------------------------------------------------------------------------------------|------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|------------------------------------------------------------------------------------|------------------|
| Orta-Gövde                                                                          | İmplant Konikliği                                                                  | İmplant Yivi                                                                        | Yiv Tipi                                                                           | Orta-Gövde Oluğu |
|                                                                                     | Konik                                                                              | Yivli                                                                               | V-Şeklinde Yivli                                                                   |                  |
|                                                                                     |   |    |   |                  |
|                                                                                     | Konik Apeks                                                                        | Yivsiz                                                                              | Ters Buttress                                                                      |                  |
|                                                                                     |  |   |  |                  |
|                                                                                     | Düz                                                                                |                                                                                     | Kare Şeklinde Yivli                                                                |                  |
|  |                                                                                    |  |                                                                                    |                  |
|                                                                                     |                                                                                    | Yuvarlak Yivli                                                                      |                                                                                    |                  |
|  |                                                                                    |                                                                                     |                                                                                    |                  |

|                                                                                     |                                                                                     |                                                                                     |                                                                                     |                                                                                      |                                                                                       |
|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------|
| Apikal                                                                              | Apeks Şekli                                                                         | Açık Apeks                                                                          | Delik Şekli                                                                         | Apikal Boşluk                                                                        | Apikal Oluk                                                                           |
|                                                                                     | V-Şeklinde Apeks                                                                    |  | Yuvarlak                                                                            |  |  |
|                                                                                     |  |                                                                                     |  |                                                                                      |                                                                                       |
|                                                                                     | Kavisli Apeks                                                                       |                                                                                     | Oblong                                                                              |                                                                                      |                                                                                       |
|  |                                                                                     |  |                                                                                     |                                                                                      |                                                                                       |
| Düz Apeks                                                                           |                                                                                     |                                                                                     |                                                                                     |                                                                                      |                                                                                       |
|  |                                                                                     |                                                                                     |                                                                                     |                                                                                      |                                                                                       |

Şekil 2.3. Radyografik özelliklerine göre implant sınıflaması<sup>(26)</sup>

#### 2.1.4. İmplant Görüntüleme Yöntemleri

İmplant görüntülemesinde kullanılacak yöntem, cerrahi sahadan elde edilmek istenen bilgi ve tedavi fazı gibi etkenlere göre değişkenlik gösterir (Tablo 2.1). İmplant cerrahisi öncesi görüntülemelerde amaç, kemik kalitesi ve miktarı, implantın uygulanacağı sahanın komşu anatomik yapılarla ilişkisi, implant oryantasyonu; cerrahi sırasındaki amaç, implant pozisyon ve oryantasyonu; cerrahi sonrası amaç, alveol kemiğinde iyileşmeyi, implant pozisyonunu değerlendirmektir.<sup>(27)</sup>

**Tablo 2.1.** İmplant görüntüleme yöntemleri

| Konvansiyonel Görüntüleme Yöntemleri                                                                                                                                                                                                                     | İleri Görüntüleme Yöntemleri                                                                                                                                                                     |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <ul style="list-style-type: none"><li>• Periapikal Radyografi</li><li>• Bitewing Radyografi</li><li>• Okluzal Radyografi</li><li>• Sefalometrik Radyografi</li><li>• Panoramik Radyografi</li><li>• Transtomografi</li><li>• Dijital Tomografi</li></ul> | <ul style="list-style-type: none"><li>• Manyetik Rezonans Görüntüleme</li><li>• Konvansiyonel Tomografi</li><li>• Bilgisayarlı Tomografi</li><li>• Konik Işınlı Bilgisayarlı Tomografi</li></ul> |

#### Periapikal Radyografi

Periapikal radyografide görüntü elde edilirken paralel veya açıortay olmak üzere iki intraoral projeksiyon tekniği kullanılır. Paralel teknikte görüntü sensörü bir tutucuya yerleştirilir ve incelenmekte olan dişin uzun eksenine paralel olarak ağızda konumlandırılır, x-ışını hem dişe hem de sensöre dik açıyla yönlendirilir. Açıortay tekniğinde ise Cieszynski'nin ortak bir kenara ve iki eşit açıya sahip üçgenler eşit kuralına göre, görüntü sensörü mümkün olduğunca bükmeden, dişe yakın şekilde konumlandırılır. x-ışını dişin uzun eksen ile sensörü arasında oluşan açının açıortayına yönlendirilir.<sup>(28)</sup> Her iki teknikte de amaç görüntü distorsiyonunu azaltmak olsa da bozulma paralel teknikte daha az olduğundan dolayı daha idealdir.<sup>(29,30)</sup> Periapikal radyografi çenelerin sınırlı bir bölgesinin yüksek çözünürlüklü düzlemsel görüntüsünü verir. İlgili alandaki trabeküler paterni, kemik yoğunluğunu ve kritik öneme sahip anatomik yapılarla ilişkisini ortaya koyabilir.<sup>(31)</sup>


Fakat periapikal radyografi, görüntüleme alanının bukkolingual genişliği hakkında bilgi veremez.<sup>(27)</sup>

### **Panoramik Radyografi**

Panoramik görüntüleme, maksiller ve mandibular dental arkları ve bunları fasiyal yapıların film üzerinde tek bir görüntüsünün oluşturulmasını sağlayan tekniktir.<sup>(32)</sup>

Panoramik radyografinin bir diğer adı ortopantomografidir. Bu terim Yunanca şu kelimelerden oluşur; orto = “ortos” ‘dik, düzgün’ (dişin uzun eksenine dik gelen ışın demeti), pan = “pan” ‘hepsi, tümü’ (iki dental arkın görüntülenmesi), tomo = “tomos” ‘kesit’ (kesit görüntüleri) ve grafi = “grafia” ‘yazmak, çizmek, aktarmak’ (görüntü oluşturma).<sup>(33)</sup>

Panoramik radyografi tekniğinde görüntü, dönen bir x-ışını kaynağı tarafından oluşturulan, maksilla ve mandibulanın değişken kalınlıktaki kavisli bir kesitidir. Işın kaynağı ve görüntü sensörünün hasta etrafında dönmesi nedeniyle görüntüleme alanı içerisindeki obje ve dokuların net olarak görülebildiği kavisli bir odak koridoru (*focal trough* veya imaj tabakası) oluşur.<sup>(34)</sup> İmaj tabakası içerisinde yer alan yapılar netken dışında kalan yapılar bulanıklaşır.<sup>(32)</sup> Panoramik radyografi, %10 ila %30 arasında değişen bir magnifikasyona sahiptir. Bazen bu, aynı panoramik görüntünün farklı alanlarında değişiklik gösterir (Şekil 2.4). Ayrıca konumlandırma hatası mevcutsa magnifikasyon değişir.<sup>(27)</sup>



**Şekil 2.4.** Dişsiz mandibulanın implant öncesi değerlendirmesi için alınmış panoramik görüntüde hastanın ağızında opak işaretleyicili (5 mm çapında metal küreler) radyografik stentlerde oluşan farklı miktarlardaki magnifikasyon<sup>(27)</sup>

Panoramik radyografi endikasyonları:

- Dentisyonun genel deęerlendirmesi
- Gml diřlerin deęerlendirilmesi
- Daimi dentisyonun srmesinin deęerlendirilmesi
- Kistler, tmrler ya da enfeksiyonlar gibi kemik ii patolojilerin incelenmesi
- Periodontal hastalıklarda alveol kemik ykseklięinin deęerlendirilmesi
- İmplant ncesi her iki enenin deęerlendirilmesi
- Temporomandibular eklemin kabaca deęerlendirilmesi
- Dentomaksillofasiyal travma
- Maksillofasiyal iskeletin geliřimsel bozuklukları

Panoramik radyografinin avantajları:

- Dentisyonu ve maksillofasiyal kemikleri geniř kapsamlı gsterme
- Dřk radyasyon dozu
- Trismuslu hastalarda kullanılabilmesi
- Hızlı ve kullanıřlı bir teknik olması
- Pozisyonlama kolaylıęı ve zaman tasarrufu
- Hastalar tarafından daha kolay algılandığından eęitimin kolaylařması

Panoramik radyografinin dezavantajları:

- Periapikal grntlemeye gre daha az znrlk
- Grnt boyunca magnifikasyonun olması nedeniyle lmlerin gvenilir olmaması
- Gerek, ift ve hayalet grntlerin sperpozisyonu nedeniyle bazı durumlarda tanı koymanın zorlařması
- řiddetli maksillofasiyal deformitesi olan hastalarda ideal grnt oluřturmanın zorluęu<sup>(28,32,35)</sup>

İmplant tedavisinde panoramik radyografi, alveol kemięi, mevcut diřleri, komřu anatomik yapıların konumunu ve kemik patolojisi varlığını deęerlendirmek iin faydalı bir tekniktir. Panoramik radyografi, herhangi bir konumlandırma hatası yapılmadıęı takdirde alveol kemik ykseklięi, kemik kalitesi ve yoęunluęu ile mandibular kanal, maksiller sins ve nazal kavitenin kortikal sınırlarının n deęerlendirmesinde yararlıdır.<sup>(27)</sup> Dięer yandan panoramik grntlemedeki vertikal ve horizontal magnifikasyon, grntde distorsiyon yaratarak imaj zerindeki lm

hassasiyetini düşürür. Görüntü kalitesi periapikal radyografiye göre düşük olmakla beraber panoramik radyografi de üç boyutlu yapıların iki boyutlu görüntüsünü yansıtır, dolayısıyla maksillofasiyal yapılardaki kemik kalınlığına dair bilgi veremez.<sup>(27,36,37)</sup>


## **2.2. Yapay Zeka**

### **2.2.1. Yapay Zeka Nedir?**

Yapay zeka (*artificial intelligence - AI*), normalde insanın bilme yetisini (algı, dil, anlama, akıl yürütme, öğrenme, planlama ve problem çözme) gerektiren görevleri yerine getirebilen bilgisayar sistemlerinin teorisini ve gelişimini tanımlamak için kullanılan genel bir terimdir.<sup>(38)</sup>

### **2.2.2. Yapay Zeka Tarihçesi**

Alan Turing 1936 yılında yazdığı bir makalede mümkün olan her hesaplamının sonradan “Turing makinesi” adını alacak bir matematiksel sistemle gerçekleştirilebileceğini göstermiştir. Bu hayali sistem ‘0’ ve ‘1’lerle temsil edilen ikili (*binary*) sembollerin kombinasyonlarından oluşmaktadır. Fakat bu temellere dayanan fiziksel bir bilgisayarın geliştirilmesi için 10 yıl kadar daha beklenmesi gerekmiştir.<sup>(39,40)</sup> Turing, 1950 yılında yazdığı “Computing Machinery and Intelligence” adlı makalede makinelerin düşünüp düşünemeyeceğine sorusuna yanıt verebilmek için “Turing Testi”ni önermiştir. Turing Testi temelde iki insan ve bir bilgisayardan oluşan üç oyunculu bir oyundur. Bir insan değerlendirmeci, ayrı bir odada tutulan bir bilgisayar ve bir insana hangisinin insan olduğunu saptayabilmek için açık uçlu sorular sorar. Değerlendirmeci, alınan cevaplara rağmen karar veremezse, bilgisayarın testi geçtiği ve zeka sahibi olduğuna hükmedilir.<sup>(41)</sup> Turing Testi bir makinenin büyük miktarda bilgiyi işleyebildiğini, konuşmayı yorumlayabildiğini ve insanlarla iletişim kurabildiğini gösterir.<sup>(42)</sup>



Şekil 2.5. Turing Testi<sup>(43)</sup>


2014 yılında Eugene Goostman adında, 13 yaşında Ukraynalı bir erkek çocuğunu taklit eden bir simülasyon programı, gözlemcilerin %33'ünü insan olduğuna inandırabilmiştir.<sup>(44)</sup> Bundan dört yıl sonra bir konferansta Google Assistant programı kullanılarak, karşıdaki kişi farketmeden bir kadın kuaföründen başarılı şekilde randevu alınmıştır.<sup>(45)</sup>

Diğer yandan makinelerin düşünebilmesinin ölçülmesi açısından Turing Testi'ne alternatif birçok test önerilmiştir. Felsefeci John Searle'nin 1980 tarihinde Turing Testi'ne itiraz olarak bir makalesinde, "Çince Odası" adlı düşünce deneyini önermiş ve Turing Testi'nin bir makinenin düşünme yetisini belirlemede kullanılamayacağını savunmuştur. Searle; kapalı bir odada, gelecek Çince komutlara verilecek cevapların bulunduğu program yüklenmiş bir bilgisayar ve dışarıda gerçekten Çince bilen bir insan bulunan bir deney ortamı hayal etmiştir. Argümana göre dışarıdaki insanın vereceği komutlara bilgisayar, içerisindeki program üzerinden doğru cevaplar verebilir fakat aslında bu, makinenin düşünebildiğini ve gerçekten Çince bildiğini göstermez dolayısıyla Turing Testi'ni aldatabilir.<sup>(46)</sup>

Searle aynı makalesinde yapay zekanın iki çeşidi olduğunu savunmuştur:

- Genel Yapay Zeka (*Strong Artificial Intelligence*): tüm zihinsel görevlerde insanlardan daha başarılı olan bir bilgisayar sistemini ifade eder. Genel yapay zekaya sahip bir bilgisayar sistemi teorik olarak, karmaşık sorunları çözebilir, belirsiz durumlarda karar alabilir ve mevcut durumu değerlendirirken önceki bilgilerinden yararlanabilir. DeepMind ve OpenAI gibi programlar genel yapay zekaya örnek olarak gösterilebilir ve fakat pratik anlamda bunu başarabilmiş bir program yoktur.
- Dar Yapay Zeka (*Weak Artificial Intelligence*): dar kapsamlı olarak tanımlanmış bir görevi insanlardan daha iyi yerine getirebilen bir bilgisayar sistemini ifade eder. Dar yapay zeka, insanlığın yapay zeka geliştirme konusunda şu ana dek ulaşabildiği en uç noktadır. Sürücüsüz araçlar, kişisel dijital yardımcılar, görüntü tanıma programları gibi gerçek dünyada gördüğümüz tüm yapay zeka örnekleri bu kategoriye girer.<sup>(46,47)</sup>

1943 yılında nörofizyolog Warren McCulloch ve matematikçi Walter Pitts birlikte yazdıkları makalede beyindeki sinir sinapslarının mantık ve matematikle, örneğin “VE” (AND), “VEYA” (OR) ve “DEĞİL” (NOT) gibi mantıksal operatörlerle ifade edilebileceğini öne sürmüşlerdir. Makale bir sinir ağı için ilk kez matematiksel bir model önermiştir <sup>48,49</sup>. Biyolojik bir sinir hücresinin uyarılabilmesi için üzerine aldığı enerjinin bir eşik değere ulaşması gerekir. McCulloch ve Pitts’in modeline göre yapay sinir hücresine (*perceptron*) gelen girdiler (*input*) belli bir eşiği aşarsa ilgili hücre bir çıktı (*output*) verir.<sup>(50,51)</sup> Bu model 1957’de psikolog Frank Rosenblatt tarafından IBM 704 adlı bilgisayarda uygulanmış, sonrasında Mark I Perceptron adlı makineyle hayata geçirilmiştir. Şekil 2.6’da *perceptron* yapısı şematize edilmiştir.<sup>(52)</sup>



Şekil 2.6. Perceptron yapısı<sup>(53)</sup>

“Yapay zeka” teriminin resmen tanıtıldığı, misyonunun ve adının belirlendiği yer olarak 1956 Dartmouth Konferansı gösterilir.<sup>(50)</sup> Konferans, zekanın her yönünün kesin bir şekilde tanımlanabileceği ve zekayı simüle edecek bir makinenin yapılabileceği varsayımı temelinde ilerlemiştir. Makinelerin dil kullanmaları, soyutlamalar ve kavramlar oluşturmaları, insanlara mahsus sorunları çözmeleri ve kendilerini geliştirmeleri sağlanmaya çalışılmıştır.<sup>(54)</sup>

### 2.2.3. Yapay Zeka Çeşitleri

#### Makine Öğrenmesi

Makine öğrenmesi, yapay zekanın bir alt başlığıdır (Şekil 2.7) ve açık talimatlar kullanmadan deneyimlerden öğrenerek performanslarını artıran bilgisayar modellerinin bilimsel olarak incelenmesini ifade eder. Bu nedenle, bir makine öğrenmesi algoritması, tahminler veya kararlar almak için bir model oluşturmak üzere örnek verilere ihtiyaç duyar. Veriler eğitim (*training*), doğrulama (*validation*) ve test (*testing*) olmak üzere üç sürece ayrılır.<sup>(55,56)</sup>



Şekil 2.7. Yapay zekanın temel kavramları<sup>(57)</sup>

Makine öğrenmesi verilen görev tipine göre dört yöntemle gerçekleştirilebilir: denetimli (*supervised*), denetimsiz (*unsupervised*), yarı-denetimli (*semi-supervised*) ve pekiştirmeli (*reinforcement*) (Şekil 2.8).

### Denetimli Öğrenme

Denetimli öğrenmede, algoritmaya eğitim aşamasında denetlenmiş veri etiketleri verilir. Beklenen çıktılar genellikle insan uzmanlar tarafından etiketlenir ve algoritma için gerçek işlevi görür. Algoritmanın amacı girdileri çıktılara eşleyen genel bir kuralı öğrenmektir.<sup>(58)</sup>

### Denetimsiz Öğrenme

Denetimsiz öğrenmede, öğrenme algoritmasına herhangi bir veri etiketi verilmez. Bu tür öğrenmede amaç verilerdeki gizli yapıyı bulmak ve verileri kümeler veya gruplara ayırmaktır.<sup>(58)</sup>


### Yarı-Denetimli Öğrenme

Yarı-denetimli öğrenme denetimli ve denetimsiz öğrenme arasında yer alır. Eğitim sürecinde hem etiketlenmiş hem de etiketlenmemiş veriler kullanılır. Yarı denetimli

öğrenme algoritmaları, temel olarak bazı uygulamalarda verilerin etiketlenmesinin çok pahalı veya imkansız olması nedeniyle geliştirilmiştir.<sup>(59)</sup>

### Pekiştirmeli Öğrenme

Pekiştirmeli öğrenmede, bir bilgisayar programı belirli bir görevi, olumlu ve olumsuz pekiştirme açısından geri bildirim aldığı dinamik bir ortamda gerçekleştirir. Yani açıkça öğretilmeden, çevresi ile etkileşimlerden öğrenmektir.<sup>(58,60)</sup>



### Yapay Sinir Ağları

Yapay sinir ağları düğüm, nod veya nöron olarak adlandırılan çok sayıdaki işlem elemanının bir araya gelmesinden oluşur. Biyolojik sinir ağlarını kısmi olarak taklit eden yapay sinir ağları, sinapslardaki gibi düğümlerin sıralı bir şekilde art arda birbirine bağlanmasından oluşur. Tipik olarak bu ağlar; girdi katmanı, bir veya daha fazla gizli katman ve çıktı katmanlarından oluşur. Her düğüm veya yapay sinir, bir diğerine bağlanır ve kendisiyle ilişkili bir ağırlık (*weight*) ve eşik değeri (*threshold*) sahiptir. Yapay sinir ağlarının düğümleri ve bağlantıları çok değişik biçimlerde bir araya getirilebilir. Ağlar bu düğüm ve bağlantı mimarilerine göre değişik isimler alırlar. Girdi katmanına bir veri girdiğinde, bu düğümün çıktısı belirlenen eşik değerinin üzerindeyse, o düğüm etkinleştirilerek ağın bir sonraki katmanına veri gönderilir.<sup>(61,62)</sup>

## Derin Öğrenme

Derin öğrenme makine öğrenmesinin bir alt grubudur ve aslında yapay sinir ağlarıyla iç içedir. “Derin” kelimesi sinir ağındaki katmanların derinliğini ifade eder. Basit bir sinir ağında girdi katmanı, gizli katman ve çıktı katmanı bulunurken derin sinir ağında birden fazla gizli katman bulunur.<sup>(63)</sup>

## Yapay Sinir Ağı Çeşitleri

Günümüzde çok sayıda yapay sinir ağı mevcuttur ve bazıları şunlardır<sup>(64)</sup>:

1. Perceptron
2. İleri Besleme (Feed Forward Neural Network - FF)
3. Radyal Tabanlı Fonksiyon Ağları (Radial Basis Function Network - RBF)
4. Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN)
5. Uzun/Kısa Süreli Bellek Ağları (Long/Short Term Memory – LSTM)
6. Kapılı Tekrarlayan Hücre (Gated Recurrent Unit – GRU)
7. Çift Yönlü Basit Tekrarlayan Ağlar (Bidirectional Recurrent Neural Network - BiRNN), Çift Yönlü Uzun/Kısa Süreli Bellek (Bidirectional Long/Short Term Memory - BiLSTM), Çift Yönlü Kapılı Tekrarlayan Hücre (Bidirectional Gated Recurrent Unit - BiGRU)
8. Oto-Kodlayıcılar (Autoencoders - AE)
9. Varyasyonel Oto-Kodlayıcılar (Variational Autoencoders - VAE)
10. Gürültü Giderici Oto-Kodlayıcılar (Denoising Autoencoders – DAE)
11. Seyrek Oto-Kodlayıcılar (Sparse Autoencoders – SAE)
12. Markov Zinciri (Markov Chain – MC)
13. Hopfield Ağı (Hopfield Network – HN)
14. Boltzmann Makinesi (Boltzmann Machine – BM)
15. Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine – RBM)
16. Derin İnanç Ağı (Deep Belief Network – DBN)
17. Konvolüsyonel Sinir Ağı (Convolutional Neural Network – CNN)
18. Dekonvolüsyonel Ağ (Deconvolutional Network - DN)
19. Derin Konvolüsyonel Ters Grafik Ağı (Deep Convolutional Inverse Graphics Network - DCIGN)
20. Çekişmeli Üretici Ağ (Generative Adversarial Network – GAN)
21. Sıvı Hal Makinesi (Liquid State Machine – LSM)
22. Aşırı Öğrenme Makinesi (Extreme Learning Machine – ELM)

23. Yankı Durum Ağı (Echo State Network – ESN)
24. Derin Artık Ağ (Deep Residual Network – DRN)
25. Nöral Turing Makinesi (Neural Turing Machine – NTM)
26. Farklılaşabilir Sinirsel Bilgisayar (Differentiable Neural Computers – DNC)
27. Kapsül Ağ (Capsule Network – CapsNet)
28. Kohonen Ağı (Kohonen Network – KN)
29. Dikkat Ağı (Attention Network – AN)

Tüm bu sinir ağı çeşitleri içinde görüntü analizinde en sık kullanılanı konvolüsyonel sinir ağlarıdır.

### **Konvolüsyonel Sinir Ağları**

Konvolüsyon işlemi, diğer adıyla evrişim, bir fonksiyonun şeklinin başka fonksiyon tarafından nasıl değiştirildiğini gösteren matematiksel bir işlemdir.

1959 yılında, David Hubel ve Torsten Wiesel adlı iki nörofizyolog yayınladıkları makalede bir kedi beynindeki nöronların katmanlı biçimde organize olduğunu göstermiştir. Buna göre katmanlar, önce yerel özellikleri ayıklayarak ve ardından çıkarılan özellikleri daha yüksek düzeyde temsil için bunları birleştirerek görsel kalıpları nasıl tanıyacağını öğrenir.<sup>(65)</sup> Bu çalışmadan esinlenerek Kunihiro Fukushima 1980 yılında, öğrenme yoluyla görsel kalıpları hiyerarşik olarak tanıyabilen, birden fazla katman içeren, kendi kendini organize eden bir sinir ağı olan Neocognitron'u önermiş ve bu konvolüsyonel sinir ağının ilk teorik modeli olmuştur.<sup>(66)</sup> LeCun ve arkadaşları tarafından 1989 yılında el yazısıyla yazılmış rakamları başarıyla tanımlayan LeNet-5 adlı modern bir konvolüsyonel sinir ağı ile bu ağ türünde önemli bir gelişme gerçekleştirilmiştir.<sup>(67)</sup> 2012 yılında Alex Krizhevsky ve arkadaşları tarafından geliştirilen AlexNet modeli ile görüntü tanımlama yarışmasında gösterdiği büyük başarı, konvolüsyonel sinir ağların büyük bir popülerite kazanmasını sağlamıştır.<sup>(68)</sup> Konvolüsyonel sinir ağları (CNN), görüntü tanıma ile ilgili ses tanımadan görüntü işlemeye kadar birçok alanda çığır açan sonuçlar elde etmiştir.<sup>(69)</sup>


## Konvolüsyonel Sinir Ağı Katmanları

### Girdi Katmanı (Input Layer)


Bu katman konvolüsyonel sinir ağının ilk katmanını oluşturur. Tasarlanacak modelin başarısı için bu katmandaki veri (görüntü) ham olarak ağı verilmektedir.

### Konvolüsyon Katmanı (Convolution Layer)

Sinir ağına adını veren bu katmanda mevcut görüntüden daha küçük boyutta bir filtre (*kernel*), görüntü üzerinde çeşitli piksel aralıklarında kaydırılarak tüm görüntü üzerinde gezdirilir. Bu filtreler 2x2, 3x3, 5x5 gibi farklı boyutlarda olabilir. Filtreler, bir önceki katmandan iletilen görüntülerdeki piksel değerleri ile filtre arasında çeşitli işlemler yaparak yeni çıktıları bir sonraki katmana iletir ve öncekinden daha küçük boyutta, özellik haritası denilen yeni bir görüntü oluşturur. Yapılan işlem şu şekildedir: İlk olarak filtredeki değerler, üzerine geldiği girdi görüntüsünün değerleriyle çarpılır ve toplamı yeni özellik haritasındaki değeri oluşturur (Şekil 2.9). Filtre bu işlemi tekrarlayarak tüm görüntü üzerinde yatay ve dikey olarak adımlar (Şekil 2.10).



Şekil 2.9. Konvolüsyon katmanında filtre ile yapılan konvolüsyon işlemine örnek




Şekil 2.10. Bir görüntü üzerinde gerçekleştirilen konvolüsyon işlemine örnek

### Aktivasyon Katmanı (Activation Layer)

Aktivasyon fonksiyonu sinir ağlarının, doğrusal ilişkilere ek olarak çıktının girdiyle orantılı değişmediği doğrusal olmayan durumları da öğrenmesini de sağlar. Aktivasyon fonksiyonu, bir nörondan geçen bilgiyi işleyen bir filtre gibidir. Girdiyi alır, bir ağırlıkla çarpar, bir önyargı (*bias*) değeri ekler ve sonra nöronun çıktısını üretmek için ona bir dönüşüm uygular. Düzleştirilmiş doğrusal birim (*Rectified Linear Unit-ReLU*), sigmoid veya hiperbolik tanjant gibi doğrusal olmayan aktivasyon fonksiyonları sinir ağının verilerdeki daha karmaşık ilişkileri yakalamasına olanak tanır.

### Havuzlama Katmanı (Pooling Layer)


Bu katmanın amacı kendisinden sonra gelecek konvolüsyon katmanı için girdiyi boyutsal olarak azaltmaktır. Havuzlama katmanında gerçekleştirilen işleme alt örnekleme (*down-sampling*) de denir. Konvolüsyon katmanındaki gibi belli filtreler uygulanarak görüntüdeki piksellerin ortalaması (*mean pooling*), en büyük değerleri (*max pooling*), tüm girdiye ait değerlerin ortalaması (*general mean pooling*) gibi işlemlerle havuzlama yapılır (Şekil 2.11). Daha iyi performans gösterdiği için genellikle en büyük değer yöntemi kullanılır.



Şekil 2.11. Havuzlama çeşitlerine örnekler

### Tam Bağlı Katman (Fully Connected Layer)

Genellikle bu katman her CNN mimarisinin sonunda yer alır. Bu katmanın içinde her bir nöron, bir önceki katmanın tüm nöronlarına bağlıdır. CNN sınıflandırıcısı olarak kullanılır. Bir tür ileri beslemeli yapay sinir ağı olduğu için geleneksel çok katmanlı sinir ağının temel yöntemini izler. Tam bağlı katmanın girdisi son havuzlama veya konvolüsyon katmanından gelir. Bu girdi, özellik haritalarından oluşturulan bir vektör şeklindedir. Tam bağlı katmanın çıktısı, nihai CNN çıktısını temsil eder (Şekil 2.12).



Şekil 2.12. Tam bağlı katman örneği

### Kayıp Değer Fonksiyonu (Loss Function)


CNN modelindeki eğitim örneklerinde oluşturulan tahmini hatayı hesaplamak için çıktı katmanında bazı kayıp fonksiyonları kullanılır. Kayıp değer fonksiyonu, gerçek çıktı ile tahmin edilen çıktı arasındaki farkı ortaya koyar. Daha sonra, CNN öğrenme süreci aracılığıyla optimize edilir.<sup>(70,71)</sup>

### **Geri Besleme (Backpropagation) Algoritması**

İleri besleme algoritmasında, ağa bir girdi verisi verilir, bu veri girdi katmanından gizli katmana, sonrasında çıktı katmanına iletilir. Daha sonra ağdaki her çıktı verisi istenen çıktıyla karşılaştırılır bir kayıp değer (*loss function*) hesaplanır. Hata değeri, çıktı katmanından başlayarak geriye doğru gizli katman ve girdi katmanına ağdaki ağırlıklar (*weight*) aracılığıyla yayılır. Böylece ağdaki ağırlıklar bu algoritmayla tekrar tekrar değiştirilerek istenen gerçek çıktı değeri elde edilir.<sup>(72,73)</sup>

### **Nesne Tespiti**

Görüntü sınıflandırma, bir görüntüyü veya bir görüntüdeki nesneyi önceden tanımlanmış kategorilerden birinde sınıflandırma işlemidir. Nesne konumlandırma, bir nesnenin etrafındaki sınırlayıcı kutu (*bounding box*) olarak bilinen dikdörtgen bir kutu yardımıyla, görüntüdeki nesnenin konumunu belirleme işlemidir. Nesne tespiti; sınıflandırma ve konumlandırmanın kombinasyonu olarak düşünülebilir (Şekil 2.13).<sup>(74,75)</sup>



Şekil 2.13. Nesne tespitinin bileşenleri

## 1) Nesne Konumlandırma Teknikleri

### a) Kayan Pencerelerle Tespit

Kayan pencere yöntemi, görüntüdeki nesneyi konumlandırmak için kullanılır. Belirli bir genişlik ve yükseklikte dikdörtgen bir kutu görüntü boyunca kayar. Görüntü sınıflandırıcı, penceredeki her alanın ilgilenilen bir nesne içerip içermediğini kontrol eder. Bu teknikte, ilgilenilen nesneyi pencerenin içine sığdırmak için her döngüden sonra görüntünün üzerinde farklı boyutta bir pencere hareket eder. Kayan pencerelerle tespit yaklaşımının bilgisayar açısından hesaplama maliyeti son derece yüksektir. Pek çok bölgenin kırılması ve her birinin bağımsız olarak çalıştırılması, çok fazla işlem gücü gerektirir.

### b) Sınırlayıcı Kutu Tahmini

Kayan pencerelerle tespit yaklaşımı, hesaplama açısından maliyetli fakat verimli olmasına rağmen, hala tutarlı şekilde sınırlayıcı kutuları üretememe sorununa

sahiptir. Sınırlayıcı kutu tahmininde, kutuya ait merkez noktasının koordinatları (x,y), kutunun genişliği (w) ve kutunun yüksekliği (h) tahmin edilmeye çalışılır.

## 2) Nesne Tanımlama Sistemlerinin Bileşenleri

### a) Bölge Önerisi

Derin öğrenme modelleri, her girdiyi tarar ve ilgilenilen bir nesneyi içerebilecek bölgeleri belirler. Ayrıca, etrafında sınırlayıcı kutular oluşturulur ve bunların her birine bir tahmin puanı atar. Atanan eşik değerine dayalı tahmin puanı, görüntüdeki ilişkili nesnelerin karar verilmesine yardımcı olur. Daha yüksek puanlara sahip sınırlayıcı kutular daha sonra seçici bir arama algoritması kullanılarak ağın bir sonraki katmanı tarafından işlenir.

### b) Özellik Çıkarma ve Ağ Tahmini

Bu bileşende, nesneyi tahmin edilen sınıfına göre sınıflandırmak için her sınırlayıcı kutunun altındaki alandan görsel özellikler çıkarılır. Temel olarak, ağın sınırlayıcı kutu içindeki daha yüksek puana sahip nesneyi içerebilecek tüm bölgeleri analiz ettiği bir sınıflandırma veya tahmin modeli kullanır. Bu bileşenin çıktıları, sınırlayıcı kutulara ait değerler ve sınıfın olasılığıdır.

### c) Maksimum Olmayanı Baskılama (*Non-max Supression*)


Bu bileşende aynı nesne üzerinde birden fazla sınırlayıcı kutu olmasını önlenir. Maksimum olmayanı baskılama, aynı nesnenin yakınındaki tüm sınırlayıcı kutulara bakar, maksimum tahmin olasılığına sahip kutuyu kontrol eder ve diğer kutuları baskılar veya kaldırır.<sup>(74,75)</sup>

## YOLO Algoritması

YOLO (You Only Look Once) 2015 yılında Redmon ve arkadaşları tarafından gerçek zamanlı bir nesne tespit algoritması olarak tanıtılmıştır.<sup>(76)</sup> Zaman içinde çeşitli versiyonları geliştirilmiş ve sunulmuştur. “Sadece bir kez bak” anlamına gelen algoritma, nesne tespitini tek seferde ve yüksek hızda gerçekleştirmektedir.

YOLO algoritmasına giren bir görüntü, öncelikle ızgara hücresi (*grid cell*) denilen parçalara bölünür, sonrasında tek katmandan geçirilerek sınıflandırılır ve nesne konumunu ifade eden “*bounding box*” adı verilen sınırlayıcı kutu ile temsil edilir. Sınırlayıcı kutu; kutunun merkez koordinatları, kutunun genişliği ve yüksekliği, kutu içinde kalan nesnenin sınıfı gibi parametrelerden oluşur (Şekil 2.14). Makinenin girdi

görüntüyü anlaması, analiz etmesi ve yorumlaması için görüntüye ait verinin vektör halinde temsil edilmesi gerekmektedir (Şekil 2.14).



Şekil 2.14. YOLO'nun çalışma mantığı ve vektör yapısı

$P_c$  nesne varlığına dair güven skorudur ve 0 ile 1 arasında değerler alır. Eğer sınırlayıcı kutuda tespit edilmek istenen nesnelerden herhangi biri varsa  $P_c$  değeri 1, yoksa 0 olacaktır.  $B_x$  ve  $B_y$  değerleri sınırlayıcı kutunun merkez noktasının koordinat (x,y) değerleridir.  $B_w$  ve  $B_h$  değerleri ise sınırlayıcı kutunun piksel değeri üzerinden oransal genişliği ve yüksekliğidir.  $C_n$ , sınıf belirtecini ifade eder ve n sayısı tespit edilmek istenen nesne sayısına göre değişkenlik gösterir. Eğer örneğin birinci sınıfta sınıflandırılmış bir nesne sınırlayıcı kutu içerisinde ise  $C_1$  değeri 1, diğer  $C_n$  değerleri 0 olur.

YOLO her hücre için sınırlayıcı kutuları ve sınıf olasılıklarını tahmin ettikten sonra, gereksiz sınırlayıcı kutuları kaldırmak için maksimum olmayan baskılama kullanır.

Sonuçta YOLO algoritmasının çıktısı, görüntüde tespit edilen her nesne için sınıf olasılıklarına sahip sınırlayıcı kutuların bir listesidir.<sup>(76)</sup>

Tanıtıldığından bu yana yenilenen ve güçlendirilen algoritmanın birçok versiyonu mevcuttur:

1. YOLO
2. YOLOv2
3. YOLOv3
4. YOLOv4
5. YOLOv5
6. Scaled YOLOv4
7. YOLOR
8. YOLOX
9. YOLOv6
10. YOLOv7
11. DAMO-YOLO
12. YOLOv8
13. PP-YOLO, PP-YOLOv2 ve PP-YOLOE<sup>(77)</sup>

YOLOv5, 2020 yılında Glenn Jocher tarafından yayınlanmıştır. Kendisinden önceki versiyonlardan farkı Darknet yerine PyTorch'ta geliştirilmiş olmasıdır.<sup>(78)</sup>

YOLOv7, 2022 yılında Wang ve arkadaşları tarafından yayınlanmıştır.<sup>(79)</sup>

YOLOv8 ise 2023'ün başında YOLOv5 geliştiricileri tarafından yayınlanmıştır.<sup>(80)</sup>


YOLO algoritmalarının performans değerlendirmeleri YOLOv3'ten itibaren Microsoft Common Objects in Context (MS COCO) veri seti ile yapılmaktadır. MS COCO, 2015 yılında tanıtılan 80 nesneye ait 328 bin görüntüden oluşan bir veri setidir.<sup>(81)</sup>

#### **2.2.4. Dış Hekimliğinde Yapay Zeka Uygulamaları**

Günümüzde medikal sahada yapay zekanın hastalık teşhisinde, prognozu tahmin etmede veya hastaya özel tedavi stratejileri geliştirmede yararlı olduğu öne sürülmüştür.<sup>(82)</sup> Yapay zeka, dış hekimlerine zamana duyarlı kritik kararlar vermede yardımcı olabilir. Karar vermede hata yapan insan unsurunu ortadan kaldırabilir, dış

hekimleri üzerindeki stres yükünü azaltırken standardize edilmiş bir sağlık hizmeti kalitesi sağlar.<sup>(83)</sup> Bunun yanında yapay zeka periodontolojide, adli diş hekimliğinde, çene cerrahisinde, protetik tedavide, ortodontide, endodontide, restoratif tedavide, oral lezyonlarda ve radyolojide gün geçtikçe popülerliği artan şekilde kullanılmaktadır.

PubMed adlı biyomedikal veritabanında “*dentistry*” ve “*artificial intelligence*” anahtar kelimeleriyle yapılan bir aramada çıkan sonuçlar değerlendirildiğinde, son 10 yılda diş hekimliğinde yapay zeka çalışmalarının düzenli şekilde arttığı görülmektedir (Şekil 2.15).



Şekil 2.15. Yapay zeka kullanılarak son 10 yılda yapılan diş hekimliği çalışmaları

Periodontitis, dünya çapında milyarlarca insanı ilgilendiren ve tedavi edilmediği takdirde dişlerde mobilite ve ciddi vakalarda diş kaybına yol açan yaygın bir hastalıktır. Hastalığın teşhis ve takibi için dental radyografiler yaygın kullanılan bir yöntemdir. Periodontoloji ile ilgili yapay zeka kullanılarak yapılan çalışmalarda doğal dişlerdeki kemik kaybı miktarı, implant çevresi kemik miktarı, periodontal hastalık gelişim riski ölçülmüştür.<sup>(84-86)</sup>

Ağız, Diş ve Çene cerrahının hastaların sağlığı için hızlı ve karmaşık kararlar alması gerekir. Yapay zeka tarafından sağlanan teknikler, cerrahın hasta yönetiminin teşhis,

karar, cerrahi prosedür, takip gibi tüm aşamalardaki uygulamalarını geliştirme potansiyeline sahiptir.<sup>(87)</sup> Bu alanda, mandibular üçüncü molar açılanması, çekimi sırasında yaşanabilecek güçlük ve olası komplikasyonlar üzerine yapay zeka kullanılarak çalışmalar yapılmıştır.<sup>(88-90)</sup>

Protetik diş tedavisi alanında, hastaların kayıp dişlerinin rehabilitasyonunda da yapay zekanın kullanıldığını görülmektedir. Bu bağlamda yapay zeka renk eşleştirmesinde, protetik tedavilerde iş akışını iyileştirmede ve kuronların desimantasyon ihtimalini hesaplamada kullanılmıştır.<sup>(91-93)</sup>

Ortodonti alanında yapay zeka; tedavi planlamasında, frontal ve lateral sefalometrik noktaları yerleştirmede, büyüme ve gelişme dönemlerini tahmin etmede başarıyla kullanılmıştır.<sup>(94-97)</sup>

Endodonti alanında, panoramik ve konik ışınli bilgisayarlı tomografik görüntüler kullanılarak yapay zeka yardımıyla apikal lezyon ve vertikal kök kırığı teşhisi yapılmıştır.<sup>(98-101)</sup>

Diş çürükleri dünyada en sık rastlanan hastalıklardan biridir ve çürük teşhisi çoğunlukla görsel ve radyografik verilere dayanır. Birçok araştırmacı sinir ağlarının diş çürüğü teşhis performansını çeşitli çürük görüntüleme yöntemleri üzerinden gelen verilerle değerlendirmiştir ve bu çalışmalarda yapay zeka insan gözlemcilerle göre çoğunlukla hızlı ve tutarlı bulunmuştur.<sup>(102-104)</sup> Ayrıca başka bir çalışmada çeşitli çürük temizleme yöntemlerinin etkinliği, uygulama sonrası oluşacak bakteri kolonizasyonu üzerinden tahmin etmek için yapay sinir ağı kullanılmış ve yeterli bulunmuştur.<sup>(105)</sup>

Temporomandibular eklem bozukluklarını teşhiste yapay zeka; panoramik ve manyetik rezonans görüntüleri kullanılarak osteoartritler ve disk deplasmanları başarıyla teşhis edilmiştir.<sup>(106,107)</sup>

Oral kavite lezyonları ve kanserlerinde yapay sinir ağları, aftöz ülserlerin nüks ihtimalini tahmin etmede, oral kanserleri fotoğraflar üzerinden teşhiste ve tümör

sağkalım, nüks ve post-operatif komplikasyon riskini tahmin etmede kullanılmıştır.<sup>(108–113)</sup>

Adli diş hekimliği, esas olarak ağız boşluğunun kendine has yapılarını değerlendirerek bir bireyin kimliğinin belirlenmesi ile ilgilenen bir diş hekimliği dalı olarak tanımlanabilir.<sup>(114)</sup> Yapay sinir ağları örüntü tanımada vaat ettikleriyle adli diş hekimliğinde yardımcı olarak kullanılabilir. Literatürde ısırma izini tanıma, cinsiyet belirleme, mandibular üçüncü molar gelişimine dayalı yaş tahmini gibi çalışmalar mevcuttur.<sup>(115–117)</sup>

### **İmplant Tespitinde Kullanılan Yapay Zeka Uygulamaları**

Dental implant uygulaması uzun süren, hassas ve invaziv bir tedavidir. Uygulamada kullanılan birçok parça mevcuttur ve implant tipinin bilinmemesi bu parçalarının yerine konmasını zorlaştırır. İmplant marka ve modelinin tanımlanabilmesi için iki boyutlu dental radyografiler üzerinde yapılan yapay zeka çalışmaları Tablo 2.2’de verilmiştir.

**Tablo 2.2.** Yapay zeka kullanılarak yapılan dental implant tanımlama çalışmaları

| Yazar                              | Kullanılan görüntü      | Görüntü sayısı | İmplant tür sayısı | Algoritma adı                                                     | Doğruluk                                       | Veri artırma |
|------------------------------------|-------------------------|----------------|--------------------|-------------------------------------------------------------------|------------------------------------------------|--------------|
| Said ve ark. <sup>(118)</sup>      | Periapikal ve panoramik | 1206           | 6                  | GoogleNet<br>Inception                                            | 0,938                                          | Evet         |
| Sukegawa ve ark. <sup>(2)</sup>    | Panoramik               | 8859           | 11                 | Temel CNN<br>VGG16<br>VGG19                                       | 0,860<br>0,899<br>0,880                        | Hayır        |
| Sukegawa ve ark. <sup>(119)</sup>  | Panoramik               | 9767           | 12                 | ResNet 18<br>ResNet 34<br>ResNet 50<br>ResNet 101<br>ResNet 152   | 0,9787<br>0,9800<br>0,9800<br>0,9841<br>0,9851 | Hayır        |
| Lee ve ark. <sup>(120)</sup>       | Periapikal ve panoramik | 11980          | 6                  | Otomatize derin CNN                                               | AUC=0,954                                      | Hayır        |
| Lee ve ark. <sup>(121)</sup>       | Periapikal ve panoramik | 10770          | 3                  | İnce ayarlı ve eğitilmiş derin CNN                                | AUC=0,971                                      | Evet         |
| Kim ve ark. <sup>(122)</sup>       | Periapikal              | 801            | 4                  | SqueezeNet<br>GoogleNet<br>ResNet-18<br>MobileNet-v2<br>ResNet-50 | 0,96<br>0,93<br>0,98<br>0,97<br>0,98           | Evet         |
| Takahashi ve ark. <sup>(123)</sup> | Panoramik               | 1282           | 4                  | YOLOv3                                                            | mAP=0,71                                       | Hayır        |
| Kim ve ark. <sup>(124)</sup>       | Periapikal              | 263            | 3                  | YOLOv3                                                            | 0,967                                          | Hayır        |

### 3. GEREÇ VE YÖNTEM

Bu çalışma; Akdeniz Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Kliniği'nde, Akdeniz Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu'nun 21.09.2022 tarihli 578 nolu izni alınarak gerçekleştirilmiştir (Ek-1).

#### 3.1. Görüntülerin toplanması

Çalışmada kullanılan görüntüler Akdeniz Üniversitesi Diş Hekimliği Fakültesi'nde, Ocak 2020 – Ocak 2023 arası, implant tedavisi uygulanmış hastalardan alınan panoramik radyograflardır.

Panoramik radyograflar Planmeca ProMax 2D S3 cihazında (Planmeca, Helsinki, Finlandiya) 64-68 kVp, 7-13 mA ve 16 saniye çekim protokolüyle elde edilmiştir.

Çalışmaya 1907 adet implant görüntüsü bulunduran toplam 523 adet panoramik radyograf dahil edilmiş ve jpeg dosya formatına dönüştürülmüştür.

#### Çalışmaya Dahil Edilme Kriterleri


- Hastanın dental implant tedavisinin Akdeniz Üniversitesi Diş Hekimliği Fakültesi'nde yapılmış olması
- Dental implant uygulaması sonrası çekilmiş panoramik radyografının bulunması

#### Çalışmaya Dahil Edilmeme Kriterleri

- Dental implant tedavisinin Akdeniz Üniversitesi Diş Hekimliği Fakültesi'nde yapılmış olmaması
- Panoramik radyografide ileri derecede hasta konumlandırma hatası veya artefakt bulunması
- İmplant bölgesinde herhangi bir patoloji varlığı

### 3.2. Veri Setlerinin Oluřturulması

Görüntüler kırılmadan 640 x 640 piksel boyutuna yeniden boyutlandırılmıştır. Görüntü sayısının artırılması amacıyla mevcut görüntülere rastgele şekilde döndürme açısı ve parlaklığı değıştirilerek veri artırma (augmentasyon) uygulanmıştır. Bunlar; saat yönünde veya saat yönünün tersinde 90° döndürme, -15° ile +15° aralığında döndürme ve parlaklığın %25 artırılması ya da azaltılmasıdır (Şekil 3.1). Sonuç olarak 523 adet görüntüden veri artırma sonrası 1247 adet görüntülü bir veri seti oluşturulmuştur.



**Şekil 3.1.** Veri artırma ile oluşturulan görüntüye bir örnek: orijinal görüntü (üst), 640 x 640 boyutlarına küçültülmüş, 13° derece döndürme, %23 parlaklık artırma sonrası oluşturulmuş ve etiketlenmiş görüntü (alt)

Bu görüntülerin %80'i (997 görüntü) eğitim seti, %10'u (125 görüntü) doğrulama seti ve %10'u (125 görüntü) test seti olarak üçe ayrılmıştır.


### 3.3. Görüntülerin etiketlenmesi

Beş implant şirketi tarafından üretilmiş toplam yedi implant sistemi, tek araştırmacı tarafından, LabelImg 1.8.1 versiyonu kullanılarak etiketlenmiştir. Etiketlenen implant sistemleri (Tablo 3.1) ve panoramik radyografideki örnekleri (Şekil 3.2) aşağıda sunulmuştur:

1. Straumann Bone Level, Straumann
2. Straumann Tissue Level, Straumann
3. Astra Tech Implant EV, Dentsply
4. Medentika Microcone, Straumann
5. NTA Regular, Pilatus Swiss Dental
6. Implace Bone Level, AGS Medikal
7. K3Pro Rapid, Argon


**Tablo 3.1.** Çalışmadaki implant sistemlerine ait panoramik görüntü ve etiket sayısı

| İmplant Markası        | Panoramik Sayısı | Etiket Sayısı |
|------------------------|------------------|---------------|
| Straumann Bone Level   | 47               | 133           |
| Straumann Tissue Level | 53               | 131           |
| Astra Tech Implant EV  | 81               | 270           |
| Medentika Microcone    | 119              | 438           |
| NTA Regular            | 120              | 438           |
| Implace Bone Level     | 94               | 385           |
| K3Pro Rapid            | 27               | 112           |



**Şekil 3.2.** Tespit edilmeye çalışılan implantların örnek radyografik görüntüleri

Etiketleme işlemi, tespit edilmek istenen implantın çevresine dikdörtgen bir kutu çizilerek yapılmıştır (Şekil 3.3).



Şekil 3.3. LabelImg programında iki farklı implant sistemine ait YOLO formatında (siyah ok) etiketleme örneği


### 3.4. Nesne Tespit Algoritmaları

Çalışmamızda, Python açık kaynaklı kodlama dilini kullanan, Microsoft Common Objects in Context (MS COCO) ile ön eğitimden geçirilmiş YOLOv5 algoritmasının YOLOv5s, YOLOv7 ve YOLOv8 algoritmasının YOLOv8s modelleri kullanılmıştır.

Bu algoritmaların eğitimi için Google'ın NVIDIA A100-SXM 40 GB ekran kartına sahip Colab Pro+ adlı sanal bir bilgisayar hizmeti kullanılmıştır. Algoritmaların eğitimi; YOLOv5s için 50 dakika, YOLOv7 için 132 dakika ve YOLOv8s için 22 dakika sürmüştür.


### 3.5. Algoritma Performanslarının Değerlendirme Ölçütleri

İmplant sistemlerinin tahmin performansı, eğitim setinde etiketlenenlerle karşılaştırılarak birleşim üzerinden kesişim (*intersection over union*) değeri hesaplanmış ve 0,5 üzeri değerler doğru kabul edilmiştir. Buna göre doğru pozitif (DP), yanlış pozitif (YP), yanlış negatif (YN) değerleri ve hata (karmaşıklık) matrisi belirlenmiş ve bu değerler üzerinden kesinlik (*precision*), duyarlılık (*recall*), mAP ve F1 skoru hesaplanmıştır (Şekil 3.4).



Şekil 3.4. İmplant tespitinde gerçekleştirilen iş akışına ait diyagram

IoU (*Intersection over Union* – Birleşim Üzerinden Ortalama Kesişim), nesne tespiti algoritmalarında sık kullanılan değerlendirme metriklerinden biridir. IoU, tahmin edilen sınırlayıcı kutu ile etiketlenmiş imajdaki sınırlayıcı kutu arasında örtüşen alanın, aralarındaki birleşme alanına bölümüdür (Şekil 3.5).



Şekil 3.5. IoU (birleşim üzerinden kesişim)

IoU değerinin 1'e yaklaşması algoritmanın sınırlayıcı kutu tahminini, yani nesne tespitini, daha doğru yaptığını gösterir. Nesne tespit algoritmalarında genellikle 0,5 ve üzeri değerler doğru tahmin olarak kabul edilir.<sup>(125)</sup> Bu çalışmada da eşik IoU değeri 0,5 olarak değerlendirilmiş ve altındaki değerler yanlış tahmin olarak kabul edilmiştir.

Hata matrisi, tahmin modelinin performansını görselleştirmenin tablosal bir yoludur. Hata matrisindeki her bir girdi, modelin sınıfları doğru veya yanlış sınıflandırdığı tahminlerin sayısını gösterir (Tablo 3.2).

**Tablo 3.2.** Hata matrisi

|        |         |                |                |
|--------|---------|----------------|----------------|
| TAHMİN | Pozitif | Doğru Pozitif  | Yanlış Pozitif |
|        | Negatif | Yanlış Negatif | Doğru Negatif  |
|        |         | Pozitif        | Negatif        |
|        |         | GERÇEK         |                |

Doğru Pozitif (*True Positive*), algoritmanın tahmin ettiği sınırlayıcı kutu ile gerçek sınırlayıcı kutunun örtüşmesidir.

Yanlış Pozitif (*False Positive*), var olmayan bir nesnenin yanlış tespit edilmesi veya var olan bir nesnenin yanlış yerde tespit edilmesidir.

Yanlış Negatif (*False Negative*), gerçek sınırlayıcı kutunun tespit edilememesidir.

Nesne tespit algoritmalarında doğru negatif (DN) değerinin kullanılması mümkün değildir çünkü herhangi bir görüntü içinde algılanmaması gereken çok yüksek sayıda sınırlayıcı kutu mevcuttur. Dolayısıyla doğru negatif değeri ile ilişkili veriler (özgüllük, ROC eğrisi vb.) de kullanılamaz.<sup>(126)</sup>

Kesinlik (*precision*), algoritma tarafından pozitif olarak tahmin edilenlerden kaçının doğru olduğunu gösterir. Formülü:

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


Duyarlılık (*recall*), pozitif olarak tahmin edilmesi gereken sonuçların toplamda ne kadarının pozitif tahmin edildiğini gösterir. Formülü:

$$\text{Duyarlılık} = \frac{DP}{DP + YN}$$

F1 skoru (*F1 score*), bu kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Formülü:

$$F1 \text{ skoru} = 2 * \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

mAP (*mean Average Precision* – Ortalama Kesinlik Değerlerinin Ortalaması), bir veri setindeki bütün sınıflar üzerinde nesne tespit algoritmasının doğruluğunu ölçmek için kullanılan bir metriktir. mAP, kesinlik-duyarlılık eğrisinin altında kalan alan üzerinden hesaplanır. IoU'daki gibi 0 ile 1 arası değerler alır ve 1'e yakın sonuçlar algoritmanın iyi performans gösterdiğini belirtir. Çalışmamızda, yukarıda belirtildiği üzere 0,5 eşiği esaslı olarak mAP değerleri bulunmuştur.



Şekil 3.6. mAP hesaplama aşamaları

Kayıp Fonksiyonu (*Loss/Cost Function*), bir algoritmanın hata miktarını değerlendirmede kullanılan bir metriktir. Algoritmanın tahmininden gerçek değerin çıkarılması üzerinden hesaplanır ve değerin 0'a yaklaşması amaçlanır. Çalışmamızda, veri setindeki kayıp fonksiyon grafiği izlenerek belirli sayıda eğitim turundan (*epoch*) sonra iyileşme azalmaya başladığında eğitim erken durdurulmuş (*early stopping*) ve sonuçlar değerlendirilmiştir. Bu sayılar YOLOv8 algoritması için 100, YOLOv5 ve YOLOv7 algoritması için 400 *epoch*'tur.



#### 4. BULGULAR


Çalışmamızda YOLO adlı nesne tespit algoritmasının YOLOv5, YOLOv7 ve YOLOv8 adlı versiyonları kullanılarak çeşitli implant sistemlerini tanımlamadaki performansı incelenmiştir. Algoritma başarısını değerlendirmede kesinlik, duyarlılık, mAP, F1 skoru ve hata matrisleri kullanılmıştır.

YOLOv5, YOLOv7 ve YOLOv8 algoritmalarının implant sistemlerini tespit etmedeki kesinlik ve duyarlılık değerleri Tablo 4.1’de, mAP değerleri Şekil 4.1’de, F1 skorları Şekil 4.2’de ve hata matrisleri Şekil 4.3, Şekil 4.4 ve Şekil 4.5’de gösterilmiştir.

**Tablo 4.1.** YOLO algoritmalarının implantları sınıflandırmada gösterdiği kesinlik ve duyarlılık değerleri


| İmplant Markası        | Kesinlik |       |       | Duyarlılık |       |       |
|------------------------|----------|-------|-------|------------|-------|-------|
|                        | v5       | v7    | v8    | v5         | v7    | v8    |
| Tümü                   | 0,786    | 0,81  | 0,89  | 0,648      | 0,815 | 0,901 |
| Straumann Bone Level   | 0,658    | 0,47  | 0,76  | 0,193      | 0,267 | 0,667 |
| Straumann Tissue Level | 0,944    | 1     | 1     | 0,509      | 0,754 | 0,811 |
| Astra Tech Implant EV  | 0,741    | 0,754 | 0,899 | 0,679      | 0,964 | 0,929 |
| Medentika Microcone    | 0,663    | 0,752 | 0,85  | 0,827      | 0,898 | 0,968 |
| NTA Regular            | 0,961    | 0,972 | 0,952 | 0,607      | 0,841 | 0,97  |
| Implance Bone Level    | 0,882    | 0,957 | 0,976 | 0,91       | 0,967 | 0,989 |
| K3Pro Rapid            | 0,653    | 0,775 | 0,795 | 0,811      | 1     | 0,973 |

Tüm implantlar arası kesinlik değerleri YOLOv5 için 0,786, YOLOv7 0,81 ve YOLOv8 için 0,89 olarak bulunmuştur. Tüm implantlar arası duyarlılık değerleri YOLOv5 için 0,648, YOLOv7 için 0,815 ve YOLOv8 için 0,901 olarak bulunmuştur.




**Şekil 4.1.** YOLO algoritmalarının implantları sınıflandırmada gösterdiği mAP değerleri

Tüm implantlar arası mAP değerleri YOLOv5 için 0,764, YOLOv7 için 0,855 ve YOLOv8 için 0,95 olarak bulunmuştur.



**Şekil 4.2.** YOLO algoritmalarının implantları sınıflandırmada alınan F1 skorları

Tüm implantlar arası F1 skorları YOLOv5 için 0,71, YOLOv7 için 0,81 ve YOLOv8 için 0,89 olarak bulunmuştur.



Şekil 4.3. YOLOv5 algoritmasına ait hata matrisi

YOLOv5 algoritmasında doğru pozitif oranları Straumann Bone Level için 0,20, Straumann Tissue Level için 0,48, Astra Tech Implant için 0,68, Medentika Microcone için 0,86, NTA Regular için 0,61, Implance Bone Level için 0,92 ve K3Pro Rapid için 0,86 olarak bulunmuştur.



Şekil 4.4. YOLOv7 algoritmasına ait hata matrisi


YOLOv7 algoritmasında doğru pozitif oranları Straumann Bone Level için 0,25, Straumann Tissue Level için 0,96, Astra Tech Implant için 0,75, Medentika Microcone için 0,71, NTA Regular için 0,98, Implants Bone Level için 0,89 ve K3Pro Rapid için 0,64 olarak bulunmuştur.



Şekil 4.5. YOLOv8 algoritmasına ait hata matrisi

YOLOv8 algoritmasında doğru pozitif oranları Straumann Bone Level için 0,63, Straumann Tissue Level için 0,76, Astra Tech Implant için 0,91, Medentika Microcone için 0,98, NTA Regular için 0,94, Implance Bone Level için 0,98 ve K3Pro Rapid için 1 olarak bulunmuştur.

Test verisetinde YOLOv8 algoritmasıyla yapılan bir tahmine ait örnek Şekil 4.6'da gösterilmiştir.



Şekil 4.6. YOLOv8 algoritmasında implant sistemi tahminine ait bir örnek görüntü (1b: Straumann Bone Level, 1t: Straumann Tissue Level)

## 5. TARTIŞMA

Dental implantlar kaybedilen diş veya dişlerin yerine konulmasında popüler bir tedavi seçeneği haline gelmiştir. Günümüzde 300'den fazla dental implant üreticisi mevcuttur ve Avrupa Birliği ülkelerinde her yıl 1,8 milyondan fazla kez implant uygulaması yapılmaktadır.<sup>(7,127)</sup> İmplant uygulamasında kullanılan bileşenlerin her biri implantın üreticisine, tipine ve boyutuna göre değişkenlik gösterir çünkü çoğu implant şirketinin kendine has tasarım, boyut ve platform kütüphanesi mevcuttur.<sup>(8)</sup>

Panoramik radyografi, periapikal radyografi ile birlikte, dental implantların markasını ve modelini belirlemek için kullanılan en yaygın dental radyolojik incelemedir.<sup>(128)</sup>

Bu tez çalışmasında beş üreticiye ait yedi çeşit dental implantın 523 panoramik radyografideki toplam 1907 adet görüntüsü kullanılarak yapay zeka tabanlı nesne tespit yöntemlerinden YOLOv5, YOLOv7 ve YOLOv8'in dental implantları tespit ve sınıflamadaki başarısı değerlendirilmiştir.

Son yıllarda artan seyahat özgürlüğü ile hastalar dental implant tedavilerini başka ülkelerde yaptırmaktadır ve hekimler tanımadığı implant sistemlerinin komplikasyonlarıyla başbaşa kalabilmektedir.<sup>(129)</sup> Mattheos ve Janda bir vaka sunumu ile böylesi durumlarda izlenecek yöntemleri tartışmıştır.<sup>(130)</sup> İmplant komplikasyonları nedeniyle protetik değişiklik veya implantın çıkarılması gerekebilir, bu nedenle hekim, kullanılan implant sistemini ve diğer bileşenlerini bilmelidir.<sup>(131)</sup> Yapılan retrospektif bir araştırmada, implantın tanımlanamaması nedeniyle uygun üst yapısının yapılamaması implant çıkarılma sebeplerinin %3,4'ünü oluşturmuştur.<sup>(132)</sup> Radyografik verilere dayalı olarak önceden yerleştirilmiş implantları tanımlamak amacıyla yeni yöntemler geliştirmek, mevcut implantların uyumsuz bileşenlerle restore edilerek hekim ve hastalar için yeni riskler yaratmasını engelleyecektir.

Çeşitli firmalara ait implantlar az farkla birbirinden ayrılır ve doğru modeli tahmin etmek deneyimli bir göz için bile zordur. Bu zorluklar her markanın ürün çeşitliliğindeki artış ve implant pazarının sürekli büyümesi nedeniyle giderek

artmaktadır.<sup>(7)</sup> İmplantları insan gözüyle, radyografik görüntüler üzerinden tanımlamak amacıyla Sahiwal ve arkadaşları yaptığı kapsamlı çalışmalarda, toplam 40'tan fazla üreticiden elde ettiği yivli ve yivsiz implantlar üzerinde, implantlara yatay ve dikey çeşitli açılar vererek radyografik görüntülerini almış ve kategorilendirmiştir.  $-10^{\circ}$  ve  $+10^{\circ}$  arası dikey açı verilmiş implantların görüntüleri üzerinden tanımlayabildiklerini fakat bu sınırları aşan açılarda görüntüde distorsiyon nedeniyle teşhisin mümkün olmadığını belirtmişlerdir.<sup>(25,133)</sup> Benzer bir araştırmada da İtalya'daki üreticilerden alınan implantlarla radyografik görüntü üzerinden çalışma yapılmıştır.<sup>(134)</sup>

İnsan gözüyle implant tanımlamaya yönelik internette veri tabanı oluşturma çalışmaları da mevcuttur. Michelinakis ve arkadaşları yaptıkları araştırmada dünya genelindeki üreticilerden internet arama motorları aracılığıyla implant modellerine ait radyografik görüntü, tip, dayanak bağlantısı, yiv durumu gibi bilgileri toplayarak bir internet veritabanı oluşturmuştur. Çalışmada veritabanının adli diş hekimliği alanında ve hekimlerin bilmedikleri bir implant sistemini tanımlamasında yardımcı olması amaçlanmıştır.<sup>(135)</sup> Bundan başka internet üzerinden implant tanımlama amaçlı veritabanı sunan siteler de mevcuttur. *Whatimplantisthat* ve *spotimplant* gibi siteler implantlara ait radyografik görüntüler ve makroskopik özellikler üzerinden tanımlanmasını sağlayan arama motorlarıdır.<sup>(26,136)</sup> Böylesi veri tabanları doğru ve zaman kazandıran yöntemler olsa da implant tanımlamada yapay zeka kullanımı bu alanda devrim yaratacaktır.<sup>(7)</sup> Mevcut çalışmamızla yapay zeka tabanlı nesne tespit algoritmalarının implantları tanımlama performansı ölçülmüştür.

Derin öğrenme sistemleri, bilgisayarların yapay sinir ağlarına dayalı insan benzeri görevleri öğrenmesine olanak tanıyan makine öğrenmesi tekniklerini kullanır.<sup>(119)</sup> Literatürde derin öğrenme tabanlı yapay zeka modelleri ile panoramik ve periapikal radyograflar kullanılarak dental implant sınıflamasının yapıldığı sınırlı sayıda çalışma mevcuttur. Bu çalışma ile mevcut bilgi birikimini zenginleştirilerek yeni perspektifler sunulmaya çalışılmıştır.

Kim ve arkadaşları, derin sinir ağlarının periapikal radyografilerde dört farklı implant tipini tanımlayıp tanımlayamayacağını değerlendirmiştir. SqueezeNet, GoogLeNet, ResNet-18, MobileNet-v2 ve ResNet-50 mimarilerinin kullanıldığı çalışmada,

konvolüsyonel sinir ağlarının nispeten küçük bir ağ ve az sayıda görüntü ile bile dört implant vidasını yüksek doğrulukla sınıflandırabildiğini belirtmiştir.<sup>(122)</sup> Said ve arkadaşları ise, bir derin konvolüsyonel sinir ağının üç implant üreticisine ait altı modelini tespit edebilmek için GoogLeNet Inceptionv3 mimarisini kullanmış ve çok iyi performans aldığını belirtmiştir.<sup>(118)</sup> Sukegawa ve arkadaşları da derin öğrenme yöntemleri kullanarak implant tanımlamaya yönelik değişik araştırmalar yapmıştır. İnce ayarlı VGG mimarileri ve üç konvolüsyon katmanlı temel bir CNN kullanarak yaptıkları çalışmada panoramik radyograflardan alınan 11 implant sistemine ait 8859 implant görüntüsü kullanmış ve bu sistemleri karşılaştırmıştır. Sonuçta ince ayarlı VGG16 ve VGG19 CNN'lerin 11 tip dental implant sistemini panoramik görüntü üzerinden doğru bir şekilde sınıflandırabildiğini belirtmiştir.<sup>(2)</sup> Diğer bir çalışmada, panoramik görüntülerden implant markalarını ve tedavi aşamalarını kategorize etmek için beş ayrı ResNet mimarisinin çok görevli şekilde çalışırken gösterdiği performansı değerlendirmiştir. 12 implant markasına ait 9767 görüntünün kullanıldığı araştırmada sinir ağlarının kullanılması, dental implant markalarının ve tedavi aşamalarının sınıflandırılmasında yüksek geçerlilik göstermiş ve çoklu görev yaklaşımının analiz doğruluğunu artırmıştır.<sup>(119)</sup>

Yukarıda bahsedilen çalışmalar konvolüsyonel sinir ağları kullanılarak görüntü sınıflandırma algoritmaları içeren çalışmalardır. Literatürde görüntü sınıflandırma ile nesne konumlandırmayı birleştiren nesne tespiti çalışmaları az sayıdadır. Çalışmamız kapsamında yapılan Türkçe literatür taramasında ise implant sistemlerini nesne tespit veya görüntü sınıflandırma algoritmalarıyla tanımlamaya çalışan bir araştırmaya rastlanmamıştır. Bu tez çalışmasında, nesne tespit yöntemleri içinde hızı ve doğruluğu vaat etmesi ve literatürdeki eksiklik nedeniyle YOLO algoritmaları tercih edilmiştir.

YOLO algoritması, tanıtıldığı tarihten bu yana hızı ve doğruluğuyla nesne tespit algoritmaları içinde popülerlik kazanmıştır.<sup>(74)</sup> Takahashi ve arkadaşları 1282 panoramik radyografla yaptıkları çalışmada, üç üreticiye ait dört implant modelini YOLOv3 algoritmasını kullanarak tespit etmeye çalışmıştır. 1000 eğitim turu (*epoch*) ile yapılan araştırmaya göre implant sistemleri için doğru pozitif oranı 0,5'ten 0,82'ye ve ortalama kesinlik 0,51'den 0,85'e değişen değerlerde bulunmuştur. Ortalama kesinlik değerlerinin ortalaması (mAP) ise 0,71 bulunmuştur.<sup>(123)</sup> Tez

çalışmamızda beş üreticinin yedi implant sistemi dahil edilmiş ve implantlar birbirinden ayırt edilmeye çalışılmıştır. Çalışmamızda tüm implantlar için mAP değerleri; YOLOv5, YOLOv7 ve YOLOv8 için sırasıyla 0,764, 0,855 ve 0,95 olarak bulunmuştur ve mAP değerinin performans değerlendirme metriği olarak kullanıldığı Takahashi ve arkadaşlarının çalışmasındaki değerden tüm YOLO versiyonlarında yüksektir. Nesne tespit çalışmalarında mAP değerinin 0,7'nin üstünde olması iyi performans gösterdiğine işaret olsa da, net bir kriter yoktur.<sup>(123,137)</sup>

Yapılmış implant sınıflandırma çalışmaları ile bu çalışma, implant çeşidi açısından karşılaştırıldığında, yedi implant türü ile, diğer çalışmaların birçoğundan ve YOLOv3 algoritmaları kullanmış çalışmaların hepsinden yüksektir.

Görüntü sayıları incelendiğinde ise, çalışmamızdaki görüntü sayısı Kim ve arkadaşlarının YOLO çalışmasındakinden yüksek, Takahashi ve arkadaşlarının çalışması ile yakın sayıdadır. Öte yandan, çalışmamız YOLO kullanılanlar arasında veri artırma yapılan tek çalışmadır. Veri artırımı, yetersiz eğitim verisinin mevcut olduğu senaryolarda özellikle avantajlıdır.<sup>(138)</sup>

Çalışmalardaki radyograflara bakıldığında, implant tespiti için periapikal ve panoramik radyografinin ya beraber ya da tek başına kullanıldığı görülmektedir. Bu tez çalışmasında; ilk değerlendirme açısından tek pozlamayla kapsamlı görüntü sunabilmesi nedeniyle panoramik radyograflar kullanılmıştır.

Eğitim turu sayıları karşılaştırıldığında ise Takahashi ve arkadaşlarının çalışmasında 1000, Kim ve arkadaşlarının çalışmasında 100, 200 ve 300 *epoch*'tur. Çalışmamızda ise *epoch* sayıları YOLOv5 ve YOLOv7 için 400, YOLOv8 içinse 100'dür. *Epoch* sayısını artırmak sonuçların iyileşmesini sağlasa da, algoritmanın ezberlemesine (*overfitting*) ve eğitiminin daha uzun sürmesine yol açtığı için kaçınılan bir seçenektir.<sup>(139)</sup> Kaldı ki çalışmamızda, algoritmaların daha iyi performans göstermediği yerde eğitim turları (*epoch*) erkenden durdurulmuştur.

Çalışmamızdaki tüm implantlar arası değerlendirme metrikleri incelendiğinde, YOLOv5, YOLOv7 ve YOLOv8 için kesinlik değerleri sırasıyla 0,786, 0,81 ve 0,89; duyarlılık değerleri sırasıyla 0,648, 0,815 ve 0,901; mAP değerleri sırasıyla 0,764,

0,855 ve 0,95; F1 skorları sırasıyla 0,71, 0,81 ve 0,89'dur. Bu bulgulara göre YOLOv5'ten YOLOv8'e algoritma güncellendikçe kesinlik, duyarlılık, mAP ve F1 skorlarının tümünde performans giderek artmıştır.

Mevcut implantlar arasında tüm performans ölçütlerinde en düşük değerler Straumann Bone Level'da, diğer yandan kesinlikte en yüksek değer Straumann Tissue Level'dadır. Straumann Bone Level ile Straumann Tissue Level benzer sayıda görüntüye sahip olmasına rağmen kesinlik değerinde oluşan fark, doku seviyesi implantın kendine has makroskopik özellikleriyle (geniş yiv aralığı, daralan koronal kısım vb.) diğer implantlardan ayrışması ve dolayısıyla tespitinin kolaylaşmasına bağlanabilir. Benzer durum az sayıda görüntüsü mevcut fakat farklı makroskopik özelliklere sahip K3Pro Rapid için de söylenebilir. Yapılmış çalışmalar farklı şekillere sahip çeşitli dental implant tiplerinin panoramik ve periapikal görüntüler kullanılarak etkili bir şekilde tespit edilip sınıflandırılabileceğini doğrulamıştır.<sup>(2,121,122)</sup>

Duyarlılık, mAP ve F1 skorlarında ise yüksek değerler genellikle fazla sayıda görüntüsü mevcut implantlarda bulunmuştur. Literatüre bakıldığında, veri setindeki görüntü sayısı yüksek tutulan çalışmalarda yüksek performans değerleri elde edilmiştir.<sup>(2,119-121)</sup>

Hata matrisleri incelendiğinde ise dikkat çekici bulgulardan biri Straumann Bone Level'ın genellikle Medentika Microcone ile karıştırılmasıdır (YOLOv5 için %70, YOLOv7 için %30, YOLOv8 için %30). Bu durum, bahsi geçen implantların makroskopik özelliklerinin benzerliğine ve Straumann Bone Level'a ait görüntü sayısının yetersiz kalmasına bağlanabilir. Fakat tersi durumlar, yani Medentika Microcone'un Straumann Bone Level zannedildiği durumlar incelendiğinde (YOLOv5 için %3, YOLOv7 için %21, YOLOv8 için %1) hata oranlarının daha düşük olduğu görülmektedir. Bu durumsa Medentika Microcone'a ait görüntü sayısının fazla olmasına ve dolayısıyla algoritmaların yeter miktarda eğitilmiş olmasına bağlanabilir.

Son olarak tüm performans metriklerinde genel ortalamalara bakıldığında, YOLO algoritmalarının versiyonu güncellendikçe performansının arttığı görülmektedir.

Ayrıca YOLOv8 daha az sayıda eğitim turu (100 *epoch*) ile diğer algoritmalarından daha iyi sonuçlar vermiştir.

Bu çalışmada birkaç limitasyon mevcuttur. Bunlardan birincisi, kullanılan implant çeşidi sayıdır. Yapay zeka temelli ideal bir implant sınıflayıcı piyasada yüzlerce implant olmasına rağmen tüm implantları sınıflayabilmelidir. İkincisi, veri setinde kullanılan görüntü sayısının nispeten az sayıda olmasıdır ve bu durum veri artırma ile telafi edilmeye çalışılmıştır. Daha büyük veri setiyle yapılacak çalışmalarda performans artacaktır. Son olarak, görüntülerin alınmasında aynı panoramik cihazın kullanılmasıdır. Farklı cihazların kullanılmasıyla değişecek görüntü kalitesi ve magnifikasyondan yapay zeka performansının ne kadar etkilendiği de araştırılmalıdır.

## 6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, 523 panoramik radyograf üzerinde beş üreticiye ait toplam yedi implant çeşidi, yapay zeka tabanlı nesne tespit algoritmaları olan YOLOv5, YOLOv7 ve YOLOv8 kullanılarak sınıflandırılmıştır. Bildiğimiz kadarıyla bu çalışma, implant tespiti için yapay zeka sistemlerini kullanan, Türkçe literatürdeki ilk çalışmadır.

Çalışmanın sonuçlarına göre; nispeten az miktarda görüntüye rağmen, tüm implantlar arası mAP ve F1 skorlarına bakıldığında kullanılan algoritmaların 0,7 üstü değerlerde performans verdiği ve bu değerlerin yeterli olduğu söylenebilir. Kesinlik, duyarlılık, mAP ve F1 skorlarına bakıldığında YOLOv5'ten YOLOv8'e doğru tüm değerlerde gelişme izlendiği söylenebilir.

Çalışmada Akdeniz Üniversitesi Diş Hekimliği Fakültesi'nde uygulanan tüm implantlar sayısal yeterlilik, makroskopik farklılık gibi ayrımlar yapılmadan veri havuzuna dahil edildiği için az sayıda kalan ve benzeşen implantlar performans sonuçlarını düşürmüş olabilir.

Daha fazla implant sistemi ve çeşitli merkezlerden alınan heterojen veri setleriyle yapılacak çalışmalar klinikte kullanılabilir yapay zeka temelli bir programın oluşturmasını sağlayacaktır. Diğer yandan ilk safhada tüm implantları içeren yapay zeka temelli bir sınıflama çalışması yapılması zor olacağından ilk etapta belirli bir bölgede veya Türkiye çapında uygulanan implantları hedefleyen bir çalışma yürütülebilir.

Literatürde implant sınıflama için insan gözlemcilerle yapay zekayı karşılaştıran çalışma az olduğu için, bu konuda da çalışmaların artırılması fayda getirecektir.

Geçmişte insan gözüyle implant sınıflamada implantın açısal pozisyonunun önemine dair çalışmalar yapılmış olsa da, bildiğimiz kadarıyla literatürde yapay zeka kullanılarak yapılmış bir çalışma yoktur. Dolayısıyla açısal değişikliklerde yapay zeka sistemlerinin tanımlama performansını değerlendiren araştırmaların yapılması yararlı olacaktır.

YOLO algoritmalarının görüntüleri daha düşük çözünürlüğe ve kare formatına çevirmesi kaynaklı oluşan detay kaybı nedeniyle ileriki dönemde orijinal boyut ve çözünürlükteki görüntüler kullanılarak çalışmalar yapılabilir.

Bu çalışma, YOLO algoritmaları ile implant sınıflandırmasında az miktarda veriyle bile yüksek performans elde edilebileceğini göstermiş olsa da gelecekte daha kapsamlı çalışmalar yapılması beklenmektedir.



## KAYNAKLAR

1. Oshida Y, Tuna EB, Aktören O, Gençay K. Dental Implant Systems. *Int J Mol Sci*. 2010 Apr;11(4):1580–678.
2. Sukegawa S, Yoshii K, Hara T, Yamashita K, Nakano K, Yamamoto N, et al. Deep Neural Networks for Dental Implant System Classification. *Biomolecules*. 2020 Jul 1;10(7):984.
3. Molander B. Panoramic radiography in dental diagnostics. *Swed Dent J Suppl*. 1996;119:1–26.
4. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015 May 28;521(7553):436–44.
5. Suzuki K. Overview of deep learning in medical imaging. *Radiol Phys Technol*. 2017 Sep;10(3):257–73.
6. Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. *Dento Maxillo Facial Radiol*. 2022 Jan 1;51(1):20210197.
7. Saghiri MA, Freag P, Fakhrzadeh A, Saghiri AM, Eid J. Current technology for identifying dental implants: a narrative review. *Bull Natl Res Cent*. 2021 Jan 6;45(1):7.
8. Benakatti V, Nayakar R, Anandhalli M, Lagali-Jirge V. Accuracy of Machine Learning in Identification of Dental Implant Systems in Radiographs – A Systematic Review and Meta-analysis. *J Indian Acad Oral Med Radiol*. 2022 Sep 26;34.
9. Partridge E. *Origins: A Short Etymological Dictionary of Modern English*. Taylor & Francis; 1977. 992 p.
10. Resnik R. *Misch's Contemporary Implant Dentistry*. 4th ed. Elsevier; 2020. 1265 p.
11. Gaviria L, Salcido JP, Guda T, Ong JL. Current trends in dental implants. *J Korean Assoc Oral Maxillofac Surg*. 2014 Apr;40(2):50–60.
12. Ring ME. A thousand years of dental implants: a definitive history--part 1. *Compend Contin Educ Dent Jamesburg NJ* 1995. 1995 Oct;16(10):1060, 1062, 1064 passim.
13. Abraham CM. A Brief Historical Perspective on Dental Implants, Their Surface Coatings and Treatments. *Open Dent J*. 2014 May 16;8:50–5.
14. Becker MJ. Etruscan Gold Appliances: Origins and Functions as Indicated by an Example from Orvieto, Italy, in the Danish National Museum. *Dent Anthropol J*. 1994;8(3):2–8.
15. Sullivan RM. Implant dentistry and the concept of osseointegration: a historical perspective. *J Calif Dent Assoc*. 2001 Nov;29(11):737–45.
16. Rajput R, Chouhan Z, Sindhu M, Sundararajan S, Chouhan RRS. "A Brief Chronological Review of Dental Implant History." *Int Dent J Stud Res*. 2021 Feb 15;4(3):105–7.
17. Greenfield EJ. Implantation of artificial crown and bridge abutments. 1913. *Int J Oral Implantol*. 1991;7(2):63–8.

18. Linkow LI, Dorfman JD. Implantology in dentistry. A brief historical perspective. N Y State Dent J. 1991;57(6):31–5.
19. Burch RH. Dr. Pinkney Adams--a dentist before his time. Ark Dent. 1997 Sep;68(3):14–5.
20. Pasqualini U, Pasqualini ME. Treatise of Implant Dentistry: The Italian Tribute to Modern Implantology [Internet]. Carimate (IT): Ariesdue; 2009 [cited 2022 Dec 6]. Available from: <http://www.ncbi.nlm.nih.gov/books/NBK409628/>
21. Brånemark PI. Osseointegration and its experimental background. J Prosthet Dent. 1983 Sep;50(3):399–410.
22. Brånemark PI, Hansson BO, Adell R, Breine U, Lindström J, Hallén O, et al. Osseointegrated implants in the treatment of the edentulous jaw. Experience from a 10-year period. Scand J Plast Reconstr Surg Suppl. 1977;16:1–132.
23. Begum S, Peeran S. 65. Classification of Dental Implants. In: Essentials of Periodontics and Oral Implantology. 2021.
24. Sahiwal IG, Woody RD, Benson BW, Guillen GE. Macro design morphology of endosseous dental implants. J Prosthet Dent. 2002 May;87(5):543–51.
25. Sahiwal IG, Woody RD, Benson BW, Guillen GE. Radiographic identification of threaded endosseous dental implants. J Prosthet Dent. 2002 May;87(5):563–77.
26. What Implant Is That? [Internet]. [cited 2022 Dec 8]. Available from: <https://whatimplantisthat.com/>
27. Angelopoulos C, Aghaloo T. Imaging technology in implant diagnosis. Dent Clin North Am. 2011 Jan;55(1):141–58.
28. Whaites E, Drage N. Essentials of Dental Radiography and Radiology. Elsevier Health Sciences; 2013. 493 p.
29. Bean LR. Comparison of bisecting angle and paralleling methods of intraoral radiology. J Dent Educ. 1969 Dec;33(4):441–5.
30. Bhakdinaronk A, Manson-Hing LR. Effect of radiographic technique upon prediction of tooth length in intraoral radiography. Oral Surg Oral Med Oral Pathol. 1981 Jan;51(1):100–7.
31. Miles DA, Van Dis ML. Implant radiology. Dent Clin North Am. 1993 Oct;37(4):645–68.
32. White SC, Pharoah MJ. White and Pharoah's Oral Radiology: Principles and Interpretation. Elsevier Health Sciences; 2018. 706 p.
33. Pandolfo I, Mazziotti S. Orthopantomography. Springer Science & Business Media; 2014. 209 p.
34. Iannucci J, Howerton LJ. Dental Radiography - E-Book: Principles and Techniques. Elsevier Health Sciences; 2016. 482 p.

35. Harorlı A. Ağız, Diş ve Çene Radyolojisi. Nobel Tıp Kitabevleri; 2014.
36. GUPTA S, PATIL N, SOLANKI J, SINGH R, LALLER S. Oral Implant Imaging: A Review. Malays J Med Sci MJMS. 2015;22(3):7–17.
37. Monsour P, Dudhia R. Implant radiography and radiology. Aust Dent J. 2008;53(s1):S11–25.
38. Rodrigues JA, Krois J, Schwendicke F. Demystifying artificial intelligence and deep learning in dentistry. Braz Oral Res. 2021;35:e094.
39. Copeland BJ. The Essential Turing. Clarendon Press; 2004. 622 p.
40. Goldstine HH, Goldstine A. The electronic numerical integrator and computer (ENIAC). Math Comput. 1946;2(15):97–110.
41. TURING AM. I.—COMPUTING MACHINERY AND INTELLIGENCE. Mind. 1950 Oct 1;LIX(236):433–60.
42. Taulli T. Artificial Intelligence Basics: A Non-Technical Introduction. Apress; 2019. 195 p.
43. Turing testi. In: Vikipedi [İnternet]. 2022 [cited 2023 Mar 8]. Available from: [https://tr.wikipedia.org/w/index.php?title=Turing\\_testi&oldid=28215031](https://tr.wikipedia.org/w/index.php?title=Turing_testi&oldid=28215031)
44. Computer AI passes Turing test in “world first.” BBC News [Internet]. 2014 Jun 9 [cited 2022 Dec 17]; Available from: <https://www.bbc.com/news/technology-27762088>
45. Welch C. Google just gave a stunning demo of Assistant making an actual phone call [Internet]. The Verge. 2018 [cited 2022 Dec 17]. Available from: <https://www.theverge.com/2018/5/8/17332070/google-assistant-makes-phone-call-demo-duplex-io-2018>
46. Searle JR. Minds, brains, and programs. Behav Brain Sci. 1980 Sep;3(3):417–24.
47. Yapay Zeka Nedir? | Microsoft Azure [İnternet]. [cited 2022 Dec 18]. Available from: <https://azure.microsoft.com/tr-tr/resources/cloud-computing-dictionary/what-is-artificial-intelligence/>
48. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. Bull Math Biophys. 1943 Dec 1;5(4):115–33.
49. Boden MA. Artificial Intelligence: A Very Short Introduction. Oxford University Press; book.
50. Muthukrishnan N, Maleki F, Ovens K, Reinhold C, Forghani B, Forghani R. Brief History of Artificial Intelligence. Neuroimaging Clin N Am. 2020 Nov;30(4):393–9.
51. Blais A, Haziran 2001 DMU 19 A 2018 | P 30. Archived | An introduction to neural networks [Internet]. IBM Developer. 2018 [cited 2022 Dec 19]. Available from: <https://developer.ibm.com/articles/l-neural/>
52. Kanal LN. Perceptron. In: Encyclopedia of Computer Science. GBR: John Wiley and Sons Ltd.; 2003. p. 1383–5.

53. Minsky M, Papert S. Perceptrons; an Introduction to Computational Geometry. MIT Press; 1969. 272 p.
54. McCarthy J, Minsky ML, Rochester N, Shannon CE. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Mag.* 2006 Dec 15;27(4):12–12.
55. Heo MS, Kim JE, Hwang JJ, Han SS, Kim JS, Yi WJ, et al. Artificial intelligence in oral and maxillofacial radiology: what is currently possible? *Dento Maxillo Facial Radiol.* 2021 Mar 1;50(3):20200375.
56. Bishop CM. Pattern Recognition and Machine Learning. Springer New York; 2016. 738 p.
57. Soffer S, Ben-Cohen A, Shimon O, Amitai MM, Greenspan H, Klang E. Convolutional Neural Networks for Radiologic Images: A Radiologist’s Guide. *Radiology.* 2019 Mar;290(3):590–606.
58. Choy G, Khalilzadeh O, Michalski M, Do S, Samir AE, Pinykh OS, et al. Current Applications and Future Impact of Machine Learning in Radiology. 2018 Aug;288(2):318–28.
59. Wang S, Summers RM. Machine learning and radiology. *Med Image Anal.* 2012 Jul 1;16(5):933–51.
60. Alpaydin E. Introduction to Machine Learning. MIT Press; 2004. 468 p.
61. Elmas Ç. Yapay zeka uygulamaları. Seçkin Yayıncılık; 2018. book.
62. Gurney K. An Introduction to Neural Networks. CRC Press; 1997. 250 p.
63. Aggarwal CC. Neural Networks and Deep Learning: A Textbook. Springer; 2018. 512 p.
64. Leijnen F van V Stefan. The Neural Network Zoo [Internet]. The Asimov Institute. 2016 [cited 2023 Mar 8]. Available from: <https://www.asimovinstitute.org/neural-network-zoo/>
65. Hubel DH, Wiesel TN. Receptive fields of single neurones in the cat’s striate cortex. *J Physiol.* 1959 Oct;148(3):574–91.
66. Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol Cybern.* 1980 Apr 1;36(4):193–202.
67. Lecun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proc IEEE.* 1998 Nov;86(11):2278–324.
68. Krizhevsky A, Sutskever I, Hinton GE. ImageNet Classification with Deep Convolutional Neural Networks. In: *Advances in Neural Information Processing Systems* [Internet]. Curran Associates, Inc.; 2012 [cited 2023 Jan 3]. Available from: <https://papers.nips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html>

69. Albawi S, Mohammed TA, Al-Zawi S. Understanding of a convolutional neural network. In: 2017 International Conference on Engineering and Technology (ICET). 2017. p. 1–6.
70. İNİK Ö, Ülker E. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. 2017;
71. Doğan F, Türkoğlu İ. Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. DÜMF Mühendis Derg. 2019 Jun 20;10(2):409–45.
72. Brunton SL, Kutz JN. Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control. Cambridge University Press; 2019. 495 p.
73. Kishore DR, Kaur T. Backpropagation Algorithm: An Artificial Neural Network Approach for Pattern Recognition. In 2012 [cited 2023 Jan 8]. Available from: <https://www.semanticscholar.org/paper/Backpropagation-Algorithm%3A-An-Artificial-Neural-for-Kishore-Kaur/d564c2cd693586e372853a8d0d173c3dd7050110>
74. Diwan T, Anirudh G, Tembhurne JV. Object detection using YOLO: challenges, architectural successors, datasets and applications. Multimed Tools Appl. 2023 Mar 1;82(6):9243–75.
75. Poonkuntran S, Dhanraj RK, Balusamy B. Object Detection with Deep Learning Models: Principles and Applications. Chapman & Hall/CRC Press; 2022. book.
76. Redmon J, Divvala S, Girshick R, Farhadi A. You Only Look Once: Unified, Real-Time Object Detection [Internet]. arXiv; 2016 [cited 2023 Mar 10]. Available from: <http://arxiv.org/abs/1506.02640>
77. Terven J, Cordova-Esparza D. A Comprehensive Review of YOLO: From YOLOv1 to YOLOv8 and Beyond [Internet]. arXiv; 2023 [cited 2023 Apr 21]. Available from: <http://arxiv.org/abs/2304.00501>
78. Jocher G. YOLOv5 by Ultralytics [Internet]. 2020 [cited 2023 Apr 21]. Available from: <https://github.com/ultralytics/yolov5>
79. Wang CY, Bochkovskiy A, Liao HYM. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [Internet]. arXiv; 2022 [cited 2023 Apr 21]. Available from: <http://arxiv.org/abs/2207.02696>
80. Jocher G, Chaurasia A, Qiu J. YOLO by Ultralytics [Internet]. 2023 [cited 2023 Apr 21]. Available from: <https://github.com/ultralytics/ultralytics>
81. Lin TY, Maire M, Belongie S, Bourdev L, Girshick R, Hays J, et al. Microsoft COCO: Common Objects in Context [Internet]. arXiv; 2015 [cited 2023 Apr 27]. Available from: <http://arxiv.org/abs/1405.0312>
82. Shan T, Tay FR, Gu L. Application of Artificial Intelligence in Dentistry. J Dent Res. 2021 Mar;100(3):232–44.
83. Patil S, Albogami S, Hosmani J, Mujoo S, Kamil MA, Mansour MA, et al. Artificial Intelligence in the Diagnosis of Oral Diseases: Applications and Pitfalls. Diagn Basel Switz. 2022 Apr 19;12(5):1029.

84. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep Learning for the Radiographic Detection of Periodontal Bone Loss. *Sci Rep*. 2019 Jun 11;9(1):8495.
85. Cha JY, Yoon HI, Yeo IS, Huh KH, Han JS. Peri-Implant Bone Loss Measurement Using a Region-Based Convolutional Neural Network on Dental Periapical Radiographs. *J Clin Med*. 2021 Mar 2;10(5):1009.
86. Vadzyuk S, Boliuk Y, Luchynskyi M, Papinko I, Vadzyuk N. PREDICTION OF THE DEVELOPMENT OF PERIODONTAL DISEASE. *Proceeding Shevchenko Sci Soc Med Sci* [Internet]. 2021 Dec 12 [cited 2023 Jan 5];65(2). Available from: <https://mspsss.org.ua/index.php/journal/article/view/363>
87. Loftus TJ, Tighe PJ, Filiberto AC, Efron PA, Brakenridge SC, Mohr AM, et al. Artificial Intelligence and Surgical Decision-making. *JAMA Surg*. 2020 Feb 1;155(2):148–58.
88. Vranckx M, Van Gerven A, Willems H, Vandemeulebroucke A, Ferreira Leite A, Politis C, et al. Artificial Intelligence (AI)-Driven Molar Angulation Measurements to Predict Third Molar Eruption on Panoramic Radiographs. *Int J Environ Res Public Health*. 2020 Jan;17(10):3716.
89. Yoo JH, Yeom HG, Shin W, Yun JP, Lee JH, Jeong SH, et al. Deep learning based prediction of extraction difficulty for mandibular third molars. *Sci Rep*. 2021 Jan 21;11(1):1954.
90. Zhang W, Li J, Li ZB, Li Z. Predicting postoperative facial swelling following impacted mandibular third molars extraction by using artificial neural networks evaluation. *Sci Rep*. 2018 Aug 16;8(1):12281.
91. Wei J, Peng M, Li Q, Wang Y. Evaluation of a Novel Computer Color Matching System Based on the Improved Back-Propagation Neural Network Model. *J Prosthodont Off J Am Coll Prosthodont*. 2018 Oct;27(8):775–83.
92. Raith S, Vogel EP, Anees N, Keul C, Güth JF, Edelhoff D, et al. Artificial Neural Networks as a powerful numerical tool to classify specific features of a tooth based on 3D scan data. *Comput Biol Med*. 2017 Jan 1;80:65–76.
93. Yamaguchi S, Lee C, Karaer O, Ban S, Mine A, Imazato S. Predicting the Debonding of CAD/CAM Composite Resin Crowns with AI. *J Dent Res*. 2019 Oct;98(11):1234–8.
94. Li P, Kong D, Tang T, Su D, Yang P, Wang H, et al. Orthodontic Treatment Planning based on Artificial Neural Networks. *Sci Rep*. 2019 Feb 14;9(1):2037.
95. Muraev AA, Tsai P, Kibardin I, Oborotistov N, Shirayeva T, Ivanov S, et al. Frontal cephalometric landmarking: humans vs artificial neural networks. *Int J Comput Dent*. 2020;23(2):139–48.
96. Hwang HW, Park JH, Moon JH, Yu Y, Kim H, Her SB, et al. Automated Identification of Cephalometric Landmarks: Part 2-Might It Be Better Than human? *Angle Orthod*. 2019 Jul 22;90(1):69–76.
97. Kök H, Izgi MS, Acilar AM. Determination of growth and development periods in orthodontics with artificial neural network. *Orthod Craniofac Res*. 2021;24(S2):76–83.

98. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, et al. Deep Learning for the Radiographic Detection of Apical Lesions. *J Endod*. 2019 Jul;45(7):917-922.e5.
99. Setzer FC, Shi KJ, Zhang Z, Yan H, Yoon H, Mupparapu M, et al. Artificial Intelligence for the Computer-aided Detection of Periapical Lesions in Cone-beam Computed Tomographic Images. *J Endod*. 2020 Jul 1;46(7):987–93.
100. Orhan K, Bayrakdar IS, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *Int Endod J*. 2020;53(5):680–9.
101. Fukuda M, Inamoto K, Shibata N, Arijji Y, Yanashita Y, Kutsuna S, et al. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiol*. 2020 Oct;36(4):337–43.
102. 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 Oct;77:106–11.
103. Hung M, Voss MW, Rosales MN, Li W, Su W, Xu J, et al. Application of machine learning for diagnostic prediction of root caries. *Gerodontology*. 2019 Dec;36(4):395–404.
104. Geetha V, Aprameya KS, Hinduja DM. Dental caries diagnosis in digital radiographs using back-propagation neural network. *Health Inf Sci Syst*. 2020 Dec;8(1):8.
105. Javed S, Zakirulla M, Baig RU, Asif SM, Meer AB. Development of artificial neural network model for prediction of post-streptococcus mutans in dental caries. *Comput Methods Programs Biomed*. 2020 Apr;186:105198.
106. Choi E, Kim D, Lee JY, Park HK. Artificial intelligence in detecting temporomandibular joint osteoarthritis on orthopantomogram. *Sci Rep*. 2021 May 13;11(1):10246.
107. Orhan K, Driesen L, Shujaat S, Jacobs R, Chai X. Development and Validation of a Magnetic Resonance Imaging-Based Machine Learning Model for TMJ Pathologies. *BioMed Res Int*. 2021 Jul 5;2021:6656773.
108. Dar-Odeh NS, Alsmadi OM, Bakri F, Abu-Hammour Z, Shehabi AA, Al-Omiri MK, et al. Predicting recurrent aphthous ulceration using genetic algorithms-optimized neural networks. *Adv Appl Bioinforma Chem*. 2010 May 14;3:7–13.
109. Aubreville M, Knipfer C, Oetter N, Jaremenko C, Rodner E, Denzler J, et al. Automatic Classification of Cancerous Tissue in Laserendomicroscopy Images of the Oral Cavity using Deep Learning. *Sci Rep*. 2017 Sep 20;7(1):11979.
110. Uthoff RD, Song B, Sunny S, Patrick S, Suresh A, Kolur T, et al. Point-of-care, smartphone-based, dual-modality, dual-view, oral cancer screening device with neural network classification for low-resource communities. *PLOS ONE*. 2018 Ara;13(12):e0207493.
111. Fu Q, Chen Y, Li Z, Jing Q, Hu C, Liu H, et al. A deep learning algorithm for detection of oral cavity squamous cell carcinoma from photographic images: A retrospective

study. *eClinicalMedicine* [Internet]. 2020 Oct 1 [cited 2023 Jan 7];27. Available from: [https://www.thelancet.com/journals/eclinm/article/PIIS2589-5370\(20\)30302-3/fulltext](https://www.thelancet.com/journals/eclinm/article/PIIS2589-5370(20)30302-3/fulltext)

112. Pan X, Zhang T, Yang Q, Yang D, Rwigema JC, Qi XS. Survival prediction for oral tongue cancer patients via probabilistic genetic algorithm optimized neural network models. *Br J Radiol*. 2020 Aug;93(1112):20190825.
113. Alabi RO, Elmusrati M, Sawazaki-Calone I, Kowalski LP, Haglund C, Coletta RD, et al. Comparison of supervised machine learning classification techniques in prediction of locoregional recurrences in early oral tongue cancer. *Int J Med Inf*. 2020 Apr 1;136:104068.
114. Johnson A, Gandhi D, Joseph S. A Morphological Study of Tongue and its Role in Forensics Odontology. *J Forensic Sci Crim Investig*. 2018 Feb 5;7.
115. Mahasantipiya PM, Yeesarapat U, Suriyadet T, Sricharoen J, Dumrongwanich A, Thaiupathump T. Bite Mark Identification Using Neural Networks: A Preliminary Study. Hong Kong. 2011;
116. Maji A, Khaitan T, Sinha R, Sarkar S, Verma P, Shukla AK. A Novel Computer-Assisted Method of Bite Mark Analysis for Gender Determination. *J Environ Public Health*. 2018 Oct 9;2018:e7130876.
117. De Tobel J, Radesh P, Vandermeulen D, Thevissen PW. An automated technique to stage lower third molar development on panoramic radiographs for age estimation: a pilot study. *J Forensic Odontostomatol*. 2017 Dec 1;35(2):42–54.
118. Hadj Saïd M, Le Roux MK, Catherine JH, Lan R. Development of an Artificial Intelligence Model to Identify a Dental Implant from a Radiograph. *Int J Oral Maxillofac Implants*. 2020;36(6):1077–82.
119. Sukegawa S, Yoshii K, Hara T, Matsuyama T, Yamashita K, Nakano K, et al. Multi-Task Deep Learning Model for Classification of Dental Implant Brand and Treatment Stage Using Dental Panoramic Radiograph Images. *Biomolecules*. 2021 May 30;11(6):815.
120. Lee JH, Kim YT, Lee JB, Jeong SN. A Performance Comparison between Automated Deep Learning and Dental Professionals in Classification of Dental Implant Systems from Dental Imaging: A Multi-Center Study. *Diagn Basel Switz*. 2020 Nov 7;10(11):910.
121. Lee JH, Jeong SN. Efficacy of deep convolutional neural network algorithm for the identification and classification of dental implant systems, using panoramic and periapical radiographs. *Medicine (Baltimore)*. 2020 Jun 26;99(26):e20787.
122. Kim JE, Nam NE, Shim JS, Jung YH, Cho BH, Hwang JJ. Transfer Learning via Deep Neural Networks for Implant Fixture System Classification Using Periapical Radiographs. *J Clin Med*. 2020 Apr 14;9(4):1117.
123. Takahashi T, Nozaki K, Gonda T, Mameno T, Wada M, Ikebe K. Identification of dental implants using deep learning-pilot study. *Int J Implant Dent*. 2020 Sep 22;6(1):53.

124. Kim HS, Ha EG, Kim YH, Jeon KJ, Lee C, Han SS. Transfer learning in a deep convolutional neural network for implant fixture classification: A pilot study. *Imaging Sci Dent*. 2022 Jun;52(2):219–24.
125. Rezatofighi H, Tsoi N, Gwak J, Sadeghian A, Reid I, Savarese S. Generalized Intersection Over Union: A Metric and a Loss for Bounding Box Regression. In 2019 [cited 2023 Apr 22]. p. 658–66. Available from: [https://openaccess.thecvf.com/content\\_CVPR\\_2019/html/Rezatofighi\\_Generalized\\_Intersection\\_Over\\_Union\\_A\\_Metric\\_and\\_a\\_Loss\\_for\\_CVPR\\_2019\\_paper.html](https://openaccess.thecvf.com/content_CVPR_2019/html/Rezatofighi_Generalized_Intersection_Over_Union_A_Metric_and_a_Loss_for_CVPR_2019_paper.html)
126. Padilla R, Netto SL, da Silva EAB. A Survey on Performance Metrics for Object-Detection Algorithms. In: 2020 International Conference on Systems, Signals and Image Processing (IWSSIP). 2020. p. 237–42.
127. Misch CM. Editorial: The global dental implant market: Everything has a price. *Int J Oral Implantol Berl Ger*. 2020;13(4):311–2.
128. Lee JH, Kim YT, Lee JB, Jeong SN. Deep learning improves implant classification by dental professionals: a multi-center evaluation of accuracy and efficiency. *J Periodontal Implant Sci*. 2022 Jun;52(3):220–9.
129. Barrowman RA, Grubor D, Chandu A. Dental implant tourism. *Aust Dent J*. 2010 Dec;55(4):441–5.
130. Mattheos N, Janda MS. Exotic encounters with dental implants: managing complications with unidentified systems. *Aust Dent J*. 2012 Jun;57(2):236–42.
131. Sharma D, Jhingta PK. Dental implant identification, numbering, and nomenclature system: The need of the hour. *J Dent Implants*. 2019 Jan 1;9(1):46.
132. Sukegawa S, Saika M, Tamamura R, Nakano K, Takabatake K, Kawai H, et al. Clinical retrospective study of dental implant removal: do patients who require implant removal desire implant prosthesis again? *Med Oral Patol Oral Cirugia Bucal*. 2020 Nov 1;25(6):e784–90.
133. Sahiwal IG, Woody RD, Benson BW, Guillen GE. Radiographic identification of nonthreaded endosseous dental implants. *J Prosthet Dent*. 2002 May;87(5):552–62.
134. Nuzzolese E, Lusito S, Solarino B, Di Vella G. Radiographic dental implants recognition for geographic evaluation in human identification. *J Forensic Odontostomatol*. 2008 Jun 1;26(1):8–11.
135. Michelinakis G, Sharrock A, Barclay CW. Identification of dental implants through the use of Implant Recognition Software (IRS). *Int Dent J*. 2006;56(4):203–8.
136. Spotimplant | Dental Implant search engine and identification service [Internet]. Spotimplant. [cited 2023 Mar 8]. Available from: <https://www.spotimplant.com/en/>
137. Zhao ZQ, Zheng P, Xu ST, Wu X. Object Detection With Deep Learning: A Review. *IEEE Trans Neural Netw Learn Syst*. 2019 Nov;30(11):3212–32.

138. Chlap P, Min H, Vandenberg N, Dowling J, Holloway L, Haworth A. A review of medical image data augmentation techniques for deep learning applications. *J Med Imaging Radiat Oncol*. 2021;65(5):545–63.
139. Prechelt L. Early Stopping — But When? In: Montavon G, Orr GB, Müller KR, editors. *Neural Networks: Tricks of the Trade: Second Edition* [Internet]. Berlin, Heidelberg: Springer; 2012 [cited 2023 Jun 5]. p. 53–67. (Lecture Notes in Computer Science). Available from: [https://doi.org/10.1007/978-3-642-35289-8\\_5](https://doi.org/10.1007/978-3-642-35289-8_5)



**EK – 1**



## ÖZGEÇMİŞ

### Kişisel Bilgiler

|              |           |         |       |
|--------------|-----------|---------|-------|
| Adı          | TARIK ALİ | Uyruğu  | T. C. |
| Soyadı       | UĞUR      | Tel no  |       |
| Doğum tarihi |           | e-posta |       |

### Eğitim Bilgileri

| Mezun olduğu kurum |                                         | Mezuniyet yılı |
|--------------------|-----------------------------------------|----------------|
| Lise               | Haydarpaşa Anadolu Lisesi               | 2011           |
| Lisans             | Marmara Üniversitesi Diş Hekimliği Fak. | 2018           |
| Doktora            |                                         |                |

### İş Deneyimi

| Görevi | Kurum | Süre (yıl-yıl) |
|--------|-------|----------------|
|        |       |                |
|        |       |                |
|        |       |                |
|        |       |                |

| Yabancı Dilleri | Sınav türü | Puanı |
|-----------------|------------|-------|
| İNGİLİZCE       | YDS        | 98,75 |
|                 |            |       |

### Proje Deneyimi

| Proje Adı | Destekleyen kurum | Süre (Yıl-Yıl) |
|-----------|-------------------|----------------|
|           |                   |                |
|           |                   |                |

### Burslar-Ödüller:

### Yayınlar ve Bildiriler:

Taş A., Uğur T. A. , Yılmaz S. Tekrarlayan Ameloblastoma: Olgu Sunumu. Düzce Üniversitesi Sağlık Bilimleri Enstitüsü Dergisi. 2021; 11(3): 417-420.

Uğur T.A., Yılmaz S., Teledişhekimliği Uygulamaları: Literatür Derlemesi. Türkiye Klinikleri J Dental Sci. 2022;28(1):196-202 10.5336/dentalsci.2021-82918

Gök R.Ş., Uğur T. A., Özbudak İ. H., Yılmaz S. A Rare Case of Adult Embryonal Rhabdomyosarcoma Including the Mandible. Turk J Oncol 2023;38(2):254–56 doi: 10.5505/tjo.2023.3893