

T.C.  
ESKİŐEHİR OSMANGAZİ ÜNİVERSİTESİ  
DİŐ HEKİMLİĐİ FAKÜLTESİ

**KONİK IŐINLI BİLGİSAYARLI TOMOGRAFİ  
GÖRÜNTÜLERİNİN YAPAY ZEKÂ İLE  
DEĐERLENDİRİLMESİ**

**TuĐba ARI**

**AĐız, DiŐ ve Çene Radyolojisi Anabilim Dalı  
Uzmanlık Tezi**

**Tez DanıŐmanı  
Doç. Dr. İbrahim Őevki BAYRAKDAR**

**ESKİŐEHİR  
2022**

T.C.  
ESKİŐEHİR OSMANGAZİ ÜNİVERSİTESİ  
DİŐ HEKİMLİĐİ FAKÜLTESİ

**KONİK IŐINLI BİLGİSAYARLI TOMOGRAFİ  
GÖRÜNTÜLERİNİN YAPAY ZEKÂ İLE  
DEĐERLENDİRİLMESİ**

**TuĐba ARI**

**AĐız, DiŐ ve Çene Radyolojisi Anabilim Dalı  
Uzmanlık Tezi**

**Tez DanıŐmanı  
Doç. Dr. İbrahim Őevki BAYRAKDAR**

Bu çalıŐma EskiŐehir Osmangazi Üniversitesi Bilimsel AraŐtırma Projeleri Koordinasyon Birimi tarafından 202045E06 proje numarası ile desteklenmiŐtir.

**ESKİŐEHİR**  
2022

**T.C.**  
**ESKİŐEHİR OSMANGAZI ÜNİVERSİTESİ**  
**DİŐ HEKİMLİĐİ FAKÜLTESİ**  
**AĐIZ, DİŐ VE ÇENE RADYOLOJİSİ ANABİLİM DALI**

**KONİK IŐINLI BİLGİSAYARLI TOMOGRAFİ**  
**GÖRÜNTÜLERİNİN YAPAY ZEKÂ İLE DEĐERLENDİRİLMESİ**

**TuĐba ARI**

**Tez Savunma Tarihi:** 05.08.2022

**Tez DanıŐmanı** : Doç. Dr. İbrahim Őevki Bayrakdar (EskiŐehir Osmangazi Üniversitesi)

**Jüri Üyesi** : Prof. Dr. Candan Semra Paksoy (Ankara Üniversitesi)

**Jüri Üyesi** : Doç. Dr. Esra YeŐilova (EskiŐehir Osmangazi Üniversitesi)

**Jüri Üyesi** : Dr. Öğr. Üyesi Cansu Büyük (Okan Üniversitesi)

**Onay**

Bu çalıŐma yukarıdaki jüri tarafından Uzmanlık Tezi olarak kabul edilmiŐtir.

**Prof. Dr. Batu Can YAMAN**

Dekan

**Uzmanlık Tezi**

**ESKİŐEHİR-2022**

## UZMANLIK TEZİ BEYANNAMESİ

Uzmanlık tezi olarak sunduđum “**KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNİN YAPAY ZEKÂ İLE DEĞERLENDİRİLMESİ**” başlıklı arařtırmaı danıřmanım **Doç. Dr. İbrahim řevki BAYRAKDAR**’ ın rehberlik ve sorumluluđunda tamamladıđımı; alıřma protokolü ve süresince bilimsel arařtırma ve etik kurallara uygun davrandıđımı, verilerin tarafımdan toplandıđını, örneklerin tarafımda hazırlandıđını; deney, analiz ve görüntüleme işlemlerinin ilgili laboratuvar ve görüntüleme merkezinde tarafımda yapıldıđını/yaptırıldıđını, tez metnini hazırlarken kaynakanın eksiksiz olarak gösterildiđini, tezin yazım kılavuzu kurallarına uygun olarak hazırlandıđını ve belirtilen hususların aksinin ortaya ıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim.

**Tuđba ARI**

# İÇİNDEKİLER

|  |      |
|--|------|
| TEŞEKKÜR.....  | V    |
| ÖZET.....  | VI   |
| ABSTRACT.....  | VII  |
| SİMGELER VE KISALTMALAR DİZİNİ.....                  | VIII |
| ŞEKİLLER DİZİNİ.....                                 | X    |
| TABLolar DİZİNİ.....                                 | XVII |
| 1. GİRİŞ.....  | 1    |
| 2. GENEL BİLGİLER.....                               | 3    |
| 2.1. Konik Işınlı Bilgisayarlı Tomografi (KİBT)..... | 3    |
| 2.2. Yapay Zekâ Nedir?.....                          | 4    |
| 2.3. Makine Öğrenimi.....                            | 6    |
| 2.4. Yapay Sinir Ağları.....                         | 6    |
| 2.4.1. Yapay Sinir Ağı Modelleri.....                | 9    |
| 2.4.1.1. Tek Katmanlı Algılayıcılar.....             | 9    |
| 2.4.1.2. Çok Katmanlı Algılayıcılar.....             | 9    |
| 2.4.1.3. İleri Beslemeli Yapay Sinir Ağları.....     | 10   |
| 2.4.1.4. Geri Beslemeli Yapay Sinir Ağları.....      | 10   |
| 2.5. Derin Öğrenme.....                              | 11   |
| 2.5.1. Derin Öğrenme Mimarileri.....                 | 12   |
| 2.5.1.1. Evrişimli Sinir Ağları.....                 | 12   |

|   |           |
|---|-----------|
| 2.5.1.2. Tekrarlayan Sinir Ağları .....   | 14        |
| 2.5.1.3. Uzun-Kısa Süreli Hafıza (Long Short-Term Memory-LSTM).....                         | 15        |
| 2.5.1.4. Sınırlı Boltzmann Makinesi .....   | 16        |
| 2.5.1.5. Derin İnanç Ağı .....  | 17        |
| 2.5.1.6. Derin Oto-kodlayıcılar .....   | 17        |
| 2.5.2. Derin Öğrenmede Görüntü Segmentasyonu .....  | 18        |
| 2.5.2.1. Bölge Tabanlı Evrişimli Sinir Ağı (Region-Based Convolutional Network R-CNN) ..... | 18        |
| 2.5.2.2. Kodlayıcı-Kod Çözücü Modeller .....  | 19        |
| 2.5.3. Derin Öğrenme Modelleri .....  | 20        |
| 2.5.4. Derin Öğrenme Kütüphaneleri .....  | 20        |
| <b>3. MATERYAL VE METOT</b> .....   | <b>21</b> |
| 3.1. Hasta Seçimi.....  | 21        |
| 3.2. Radyografik Veri Setinin Elde Edilmesi.....  | 21        |
| 3.3. Görüntü Değerlendirilmesi.....   | 22        |
| 3.3.1. YZ modeli geliştirmek için etiketleme yapılan durumlar .....                         | 22        |
| 3.4. Derin Öğrenme Mimarisi.....  | 26        |
| 3.5. Model Geliştirilmesi.....  | 27        |
| 3.6. Eğitim Aşaması.....  | 27        |
| 3.7. İstatiksel Analiz.....   | 43        |
| 3.7.1. Karışıklık Matrisi Hesaplama Prosedürü .....   | 43        |
| 3.8. Performans Değerlendirilmesi.....  | 43        |

|  |            |
|--|------------|
| 3.9. Alıcı İşlem Karakteristiđi (Receiver Operating Characteristic-ROC)..... | 45         |
| <b>4. BULGULAR.....</b>  | <b>46</b>  |
| 4.1. Çürük Tespiti.....  | 48         |
| 4.2. Restoratif Dolgu Materyali Tespiti.....                                 | 50         |
| 4.3. Kök Kanal Dolgu Materyali Tespiti.....                                  | 53         |
| 4.4. Dental İmplant Tespiti.....   | 55         |
| 4.5. İmplant Destekli Kuron Tespiti.....                                     | 57         |
| 4.6. Kuron Tespiti.....  | 59         |
| 4.7. Pontik Tespiti.....   | 61         |
| 4.8. Gömülü Diş Tespiti.....   | 64         |
| 4.9. Sürnümerer Diş Tespiti.....   | 66         |
| 4.10. Rezidüel Diş Kökü Tespiti.....   | 68         |
| 4.11. Osteosklerotik Alan Tespiti.....                                       | 71         |
| 4.12. Periapikal Lezyon Tespiti.....   | 73         |
| 4.13. Radyolüsent Çene Lezyonu Tespiti.....                                  | 76         |
| 4.14. Radyopak Çene Lezyonu Tespiti.....                                     | 78         |
| 4.15. Mikst Görünümlü Çene Lezyonu Tespiti.....                              | 81         |
| <b>5. TARTIŞMA.....</b>  | <b>84</b>  |
| <b>6. SONUÇLAR VE ÖNERİLER.....</b>  | <b>95</b>  |
| <b>KAYNAKLAR.....</b>  | <b>96</b>  |
| <b>EKLER.....</b>  | <b>113</b> |
| <b>EK-1. ÖZGEÇMİŞ.....</b>   | <b>113</b> |



## TEŞEKKÜR

Uzmanlık tezi olarak sunduđum bu alıřmayı, deđerli bilgileri ve katkılarıyla yöneten, uzmanlık eđitimim boyunca bütün özverisiyle bilgilerini, tecrübelerini benimle paylaşan deđerli hocam ve tez danıřmanım Do. Dr. İbrahim řevki BAYRAKDAR' a,

Eđitim sürecim boyunca hem bilgi hem de klinik anlamda tecrübelerinden yararlandığım, yardımlarını esirgemeyen ve her zaman destek olan deđerli hocalarım Do. Dr. Esra YEŐİLOVA' ya ve Do. Dr. Elif BİLGİR' e,

alıřmamızın yapay zekâ uygulamalarıyla analizini yapan ve sonuçlarını elde eden Dr. Öğr. Üyesi Özer ELİK' e ve ekibine,

Hibir koşulda desteđini esirgemeyen sevgili arkadaşım Uzm. Dt. Hande KAZAN' a ve deđerli anabilim dalı alıřanlarına,

Hayatım boyunca her zaman yanımda olan, sevgisini, desteđini esirgemeyen sevgili aileme ve bütün uzmanlık dönemim boyunca hayatımı kolaylařtıran, sabırla, sevgisiyle hep yanımda olan en büyük destekim sevgili eřim Furkan ARI' ya,

Sonsuz teřekkürlerimi sunarım.

**Tuđba ARI**

## ÖZET

### **Konik Işınlı Bilgisayarlı Tomografi Görüntülerinin Yapay Zekâ ile Değerlendirilmesi**

**Amaç:** Yapay zekânın sağlık alanındaki görsellerin değerlendirilmesinde önemli bir potansiyele sahip olduğu görülmektedir. Bu çalışma, evrişimli sinir ağı temelli algoritmalar kullanılarak geliştirilen yapay zekâ modellerinin KIBT görüntülerinin değerlendirilmesindeki başarısını değerlendirmeyi amaçlamaktadır.

**Materyal ve Metot:** Üç yüz adet KIBT görüntüsünden oluşan veri seti üzerinde çürük, restoratif dolgu materyali, kök-kanal dolgu materyali, dental implant, implant destekli kuron, kuron, pontik, gömülü diş, sürnümerer diş, rezidüel diş kökü, osteosklerotik alan, periapikal lezyon, radyolüsent çene lezyonu, radyopak çene lezyonu, mikst görünümlü çene lezyonunu içeren 15 farklı durum için CranioCatch yazılımı (CranioCatch, Eskişehir-Türkiye) kullanılarak etiketleme yapılmıştır. Model geliştirilmesinde Mask R-CNN mimarisi ve transfer öğrenme yöntemi olarak da ResNet 101 modeli kullanılmıştır. Karışıklık matris yöntemiyle modelin başarı metrikleri hesaplanmıştır.

**Bulgular:** Yapay zekâ modelinin dental durumları tespit etme performansı değerlendirildiğinde en yüksek duyarlılık değerleri için dental implant 1, sürnümerer diş 1, kök kanal dolgu materyali 0.9863, en düşük duyarlılık değerleri için mikst görünümlü çene lezyonu 0.7857, periapikal lezyon 0.8601, osteosklerotik alan 0.875 olarak bulunmuştur. En yüksek kesinlik değerleri için dental implant 1, implant destekli kuron 1, kök kanal dolgu materyali 0.9948, en düşük kesinlik değerleri için sürnümerer diş 0.7741, mikst görünümlü çene lezyonu 0.8148, osteosklerotik alan 0.9333 olarak bulunmuştur. En yüksek F1 skoru değerleri için dental implant 1, kök kanal dolgu materyali 0.9905, implant destekli kuron 0.9876, en düşük F1 skoru değerleri için mikst görünümlü çene lezyonu 0.8, sürnümerer diş 0.8727, periapikal lezyon 0.9002 olarak bulunmuştur.

**Sonuç:** Yapay zekânın KIBT görüntüleri üzerinde farklı klinik durumların tespitindeki başarısı ümit vericidir. Yapay zekâ teşhis sürecinde hekimlere karar destek mekanizması olarak, KIBT görüntülerinin yorumlanmasında zaman kazandırmak ve tedavi planlamasına yardımcı olmak amacıyla kullanılabilir.

**Anahtar Kelimeler:** Derin öğrenme, konik ışınlı bilgisayarlı tomografi, yapay zekâ

## ABSTRACT

### Evaluation of Cone-Beam Computed Tomography Images with Artificial Intelligence

**Aim:** It is seen that artificial intelligence has an important potential in the evaluation of medical images. This study aims to evaluate the success of artificial intelligence models developed using CNN-based algorithms in the evaluation of CBCT images.

**Materials and Method:** Labeling process was done using CranioCatch annotation software (CranioCatch, Eskişehir-Turkey) for 15 different conditions including caries, restorative filling material, root-canal filling material, dental implant, implant supported crown, crown, pontic, impacted tooth, supernumerary tooth, residual root, osteosclerotic area, periapical lesion, radiolucent jaw lesion, radiopaque jaw lesion and mixed appearing jaw lesion on the data set consisting of 300 CBCT images. In model development, Mask R-CNN architecture and ResNet 101 model as transfer learning method were used for model development. The success metrics of the model were calculated with the confusion matrix method.

**Results:** When evaluating the performance of the AI model to detect dental conditions, the highest sensitivity for dental implant, supernumerary tooth, root canal filling material values were found as 1, 1, 0.9863, respectively. The lowest sensitivity values for mixed-appearing jaw lesion, periapical lesion, osteosclerotic area were found as 0.7857, 0.8601, 0.875, respectively. The highest precision values for dental implant, implant supported crown, root canal filling material were found as 1, 1, 0.9948, respectively. The lowest precision values for supernumerary tooth, mixed appearing jaw lesion, osteosclerotic area were found as 0.7741, 0.8148, 0.9333, respectively. Highest F1 score values for dental implant, root canal filling material, implant supported crown were found as 1, 0.9905, 0.9876, respectively. The lowest F1 score values for mixed- appearing jaw lesion, supernumerary tooth, periapical lesion were found as 0.8, 0.8727, 0.9002, respectively.

**Conclusion:** The success of artificial intelligence in detecting different clinical conditions on CBCT images is promising. Artificial intelligence can be used as a decision support mechanism for physicians in the diagnosis process to save time in the interpretation of CBCT images and to assist in treatment planning.

**Keywords:** Artificial intelligence, cone beam computed tomography, deep learning,

## SİMGELER VE KISALTMALAR DİZİNİ

|          |   |
|----------|---|
| %        | : Yüzde   |
| $\kappa$ | : Kappa   |
| 2D:      | : İki Boyutlu   |
| 3D       | : Üç Boyutlu  |
| AI       | : Yapay Zekâ (Artificial intelligence)                                |
| Ark.     | : Arkadaşları   |
| AUC      | : Eğri altında kalan alan (Area Under Curve)                          |
| BT       | : Bilgisayarlı Tomografi  |
| CBCT     | : Konik Işınlı Bilgisayarlı Tomografi (Cone Beam Computed Tomography) |
| CNN      | : Evrişimli sinir ağları (Convolutional neural networks)              |
| DICOM    | : Digital Imaging and Communications in Medicine                      |
| DSC      | : Zar benzerlik katsayısı   |
| FN       | : Yanlış Negatif (False Negative)                                     |
| FOV      | : Görüş alanı (Field of View)   |
| FP       | : Yanlış Pozitif (False Positive)                                     |
| FPR      | : Yanlış pozitiflik oranı (False positive rate)                       |
| IoU      | : Birleşim üzerinden ortalama kesişim (Intersection Over Union)       |
| JPEG     | : Joint Photographic Experts Group                                    |

|                 |   |
|-----------------|---|
| KIBT            | : Konik Işınlı Bilgisayarlı Tomografi                                       |
| kVp:            | : Kilovoltaj peak   |
| LTSM            | : Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory)                   |
| mA              | : Miliamper   |
| mm              | : Milimetre   |
| mm <sup>3</sup> | : Milimetre küp   |
| PR              | : Kesinlik-Hassasiyet (Precision-Recall )                                   |
| R-CNN           | : Bölge Tabanlı Evrişimli Sinir Ağları (Region-Based Convolutional Network) |
| ROC             | : Alıcı İşlem Karakteristiği (Receiver Operating Characteristic)            |
| TME             | : Temporomandibular Eklem   |
| TP              | : Gerçek pozitif (True positive)  |
| TPR             | : Doğru pozitiflik oranı (True positive rate)                               |
| YZ              | : Yapay Zekâ  |

## ŞEKİLLER DİZİNİ

| <b><u>Şekil No</u></b>   | <b><u>Sayfa No:</u></b> |
|--|-------------------------|
| Şekil 2.1. Turing testi .....  | 5                       |
| Şekil 2.2. Yapay zekâyı oluşturan temel kavramlar.....   | 6                       |
| Şekil 2.3. Biyolojik sinir hücresi ve yapay sinir ağı .....  | 7                       |
| Şekil 2.4. Yapay sinir ağı nöron modeli .....  | 8                       |
| Şekil 2.5. Çok katmanlı algılayıcı modeli .....  | 9                       |
| Şekil 2.6. İleri beslemeli ağ yapısı .....   | 10                      |
| Şekil 2.7. Geri beslemeli ağ yapısı.....   | 11                      |
| Şekil 2.8. Evrişimli sinir ağlarının farklı katmanlarda nesne ile ilgili oluşturduğu farklı temsiller .....                | 12                      |
| Şekil 2.9. Evrişimli sinir ağının genel mimarisi .....   | 13                      |
| Şekil 2.10. Tekrarlayan sinir ağı modeli .....   | 15                      |
| Şekil 2.11. LSTM hücresi.....  | 16                      |
| Şekil 2.12. Sınırlı Boltzmann makinesi.....  | 16                      |
| Şekil 2.13. Derin inanç ağı modeli.....  | 17                      |
| Şekil 2.14. Oto-kodlayıcı şeması .....   | 17                      |
| Şekil 3.1. Çene kırpma işlemi uygulanan görüntü üzerinde çürük, restoratif dolgu materyali ve kuron etiketleme örneği..... | 23                      |
| Şekil 3.2. Çene kırpma işlemi uygulanan görüntü üzerinde kök kanal dolgu materyali ve kuron etiketleme örneği.....         | 24                      |
| Şekil 3.3. Çene kırpma işlemi uygulanan görüntü üzerinde gömülü diş etiketleme örneği .....                                | 24                      |
| Şekil 3.4. Çene kırpma işlemi uygulanan görüntü üzerinde mikst görünümlü çene lezyonu etiketleme örneği.....               | 25                      |

|  |    |
|--|----|
| <b>Şekil 3.5.</b> Çene kırpma işlemi uygulanan görüntü üzerinde radyolüsent çene lezyonu ve periapikal lezyon etiketleme örneği .....    | 25 |
| <b>Şekil 3.6.</b> Çene kırpma işlemi uygulanan görüntü üzerinde radyolüsent çene lezyonu ve gömülü diş etiketleme örneği.....            | 26 |
| <b>Şekil 3.7.</b> Mask R-CNN mimarisi.....   | 27 |
| <b>Şekil 3.8.</b> Mask R-CNN modeli gerçekleştirilen çürük tespiti için modelin gelişim aşamalarının diyagramı.....                      | 28 |
| <b>Şekil 3.9.</b> Mask R-CNN modeli gerçekleştirilen restoratif dolgu materyali tespiti için modelin gelişim aşamalarının diyagramı..... | 29 |
| <b>Şekil 3.10.</b> Mask R-CNN modeli gerçekleştirilen kök kanal dolgu materyali tespiti için modelin gelişim aşamalarının diyagramı..... | 30 |
| <b>Şekil 3.11.</b> Mask R-CNN modeli gerçekleştirilen dental implant tespiti için modelin gelişim aşamalarının diyagramı .....           | 31 |
| <b>Şekil 3.12.</b> Mask R-CNN modeli gerçekleştirilen implant destekli kuron tespiti için modelin gelişim aşamalarının diyagramı.....    | 32 |
| <b>Şekil 3.13.</b> Mask R-CNN modeli gerçekleştirilen kuron tespiti için modelin gelişim aşamalarının diyagramı .....                    | 33 |
| <b>Şekil 3.14.</b> Mask R-CNN modeli gerçekleştirilen pontik tespiti için modelin gelişim aşamalarının diyagramı .....                   | 34 |
| <b>Şekil 3.15.</b> Mask R-CNN modeli gerçekleştirilen gömülü diş tespiti için modelin gelişim aşamalarının diyagramı .....               | 35 |
| <b>Şekil 3.16.</b> Mask R-CNN modeli gerçekleştirilen sürnümerer diş tespiti için modelin gelişim aşamalarının diyagramı .....           | 36 |
| <b>Şekil 3.17.</b> Mask R-CNN modeli gerçekleştirilen rezidüel diş kökü tespiti için modelin gelişim aşamalarının diyagramı .....        | 37 |

|  |    |
|--|----|
| <b>Şekil 3.18.</b> Mask R-CNN modeli gerçekleştirilen osteosklerotik alan tespiti için modelin gelişim aşamalarının diyagramı .....          | 38 |
| <b>Şekil 3.19.</b> Mask R-CNN modeli gerçekleştirilen periapikal lezyon tespiti için modelin gelişim aşamalarının diyagramı .....            | 39 |
| <b>Şekil 3.20.</b> Mask R-CNN modeli gerçekleştirilen radyolüsent çene lezyonu tespiti için modelin gelişim aşamalarının diyagramı.....      | 40 |
| <b>Şekil 3.21.</b> Mask R-CNN modeli gerçekleştirilen radyopak çene lezyonu tespiti için modelin gelişim aşamalarının diyagramı.....         | 41 |
| <b>Şekil 3.22.</b> Mask R-CNN modeli gerçekleştirilen mikst görünümlü çene lezyonu tespiti için modelin gelişim aşamalarının diyagramı ..... | 42 |
| <b>Şekil 4.1.</b> Çürük tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP) .....  | 49 |
| <b>Şekil 4.2.</b> Çürük tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP).....   | 49 |
| <b>Şekil 4.3.</b> Çürük tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN) .....  | 49 |
| <b>Şekil 4.4.</b> Çürük tespiti için ROC eğrisi.....   | 50 |
| <b>Şekil 4.5.</b> Çürük tespiti için Precision-Recall eğrisi .....   | 50 |
| <b>Şekil 4.6.</b> Restoratif dolgu materyali gerçek ve tahmini görüntüler (Gerçek pozitif-TP) .....  | 51 |
| <b>Şekil 4.7.</b> Restoratif dolgu materyali tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP).....                              | 51 |
| <b>Şekil 4.8.</b> Restoratif dolgu materyali tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN).....                              | 52 |
| <b>Şekil 4.9.</b> Restoratif dolgu materyali tespiti için ROC eğrisi .....   | 52 |
| <b>Şekil 4.10.</b> Restoratif dolgu materyali tespiti için Precision-Recall eğrisi.....  | 53 |
| <b>Şekil 4.11.</b> Kök kanal dolgusu tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP).....                                      | 53 |

|   |    |
|---|----|
| <b>Şekil 4.12.</b> Kök kanal dolgu materyali tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)..... | 54 |
| <b>Şekil 4.13.</b> Kök kanal dolgu materyali tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)..... | 54 |
| <b>Şekil 4.14.</b> Kök kanal dolgu materyali tespiti için ROC eğrisi .....                                      | 55 |
| <b>Şekil 4.15.</b> Kök kanal dolgu materyali tespiti için Precision-Recall eğrisi.....                          | 55 |
| <b>Şekil 4.16.</b> Dental implant tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP) .....           | 56 |
| <b>Şekil 4.17.</b> Dental implant tespiti için ROC eğrisi.....  | 56 |
| <b>Şekil 4.18.</b> Dental implant tespiti için Precision-Recall eğrisi .....                                    | 57 |
| <b>Şekil 4.19.</b> İmplant destekli kuron tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP).....    | 57 |
| <b>Şekil 4.20.</b> İmplant destekli kuron tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN).....    | 58 |
| <b>Şekil 4.21.</b> İmplant destekli kuron tespiti için ROC eğrisi.....  | 58 |
| <b>Şekil 4.22.</b> İmplant destekli kuron tespiti için Precision-Recall eğrisi .....                            | 59 |
| <b>Şekil 4.23.</b> Kuron tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP) .....                    | 59 |
| <b>Şekil 4.24.</b> Kuron tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP) .....                    | 60 |
| <b>Şekil 4.25.</b> Kuron tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN) .....                    | 60 |
| <b>Şekil 4.26.</b> Kuron tespiti için ROC eğrisi.....   | 61 |
| <b>Şekil 4.27.</b> Kuron tespiti için Precision-Recall eğrisi .....   | 61 |
| <b>Şekil 4.28.</b> Pontik tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP) .....                   | 62 |
| <b>Şekil 4.29.</b> Pontik tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP) .....                   | 62 |
| <b>Şekil 4.30.</b> Pontik tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN) .....                   | 63 |
| <b>Şekil 4.31.</b> Pontik tespiti için ROC eğrisi .....   | 63 |

|   |    |
|---|----|
| <b>Şekil 4.32.</b> Pontik tespiti için Precision-Recall eğrisi .....  | 64 |
| <b>Şekil 4.33.</b> Gömülü diş tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP) ..                | 64 |
| <b>Şekil 4.34.</b> Gömülü diş tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP) ...               | 65 |
| <b>Şekil 4.35.</b> Gömülü diş tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN) ..                | 65 |
| <b>Şekil 4.36.</b> Gömülü diş tespiti için ROC eğrisi .....   | 66 |
| <b>Şekil 4.37.</b> Gömülü diş tespiti için Precision-Recall eğrisi .....                                      | 66 |
| <b>Şekil 4.38.</b> Sürnümerer diş tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)<br>.....      | 67 |
| <b>Şekil 4.39.</b> Sürnümerer diş tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)<br>.....      | 67 |
| <b>Şekil 4.40.</b> Sürnümerer diş tespiti için ROC eğrisi .....   | 68 |
| <b>Şekil 4.41.</b> Sürnümerer diş tespiti için Precision-Recall eğrisi .....                                  | 68 |
| <b>Şekil 4.42.</b> Rezidüel diş kökü tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)<br>.....   | 69 |
| <b>Şekil 4.43.</b> Rezidüel diş kökü tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)<br>.....   | 69 |
| <b>Şekil 4.44.</b> Rezidüel diş kökü tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)<br>.....   | 70 |
| <b>Şekil 4.45.</b> Rezidüel diş kökü tespiti için ROC eğrisi .....  | 70 |
| <b>Şekil 4.46.</b> Rezidüel diş kökü tespiti için Precision-Recall eğrisi .....                               | 71 |
| <b>Şekil 4.47.</b> Osteosklerotik alan tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)<br>..... | 71 |
| <b>Şekil 4.48.</b> Osteosklerotik alan tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)<br>..... | 72 |

|  |    |
|--|----|
| <b>Şekil 4.49.</b> Osteosklerotik alan tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN) .....     | 72 |
| <b>Şekil 4.50.</b> Osteosklerotik alan tespiti için ROC eğrisi.....  | 73 |
| <b>Şekil 4.51.</b> Osteosklerotik alan tespiti için Precision-Recall eğrisi .....                              | 73 |
| <b>Şekil 4.52.</b> Periapikal lezyon tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP).....        | 74 |
| <b>Şekil 4.53.</b> Periapikal lezyon tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP) .....       | 74 |
| <b>Şekil 4.54.</b> Periapikal lezyon tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN) .....       | 75 |
| <b>Şekil 4.55.</b> Periapikal lezyon tespiti için ROC eğrisi.....  | 75 |
| <b>Şekil 4.56.</b> Periapikal lezyon tespiti için Precision-Recall eğrisi .....                                | 76 |
| <b>Şekil 4.57.</b> Radyolüsent çene lezyonu tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)..... | 76 |
| <b>Şekil 4.58.</b> Radyolüsent çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)..... | 77 |
| <b>Şekil 4.59.</b> Radyolüsent çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)..... | 77 |
| <b>Şekil 4.60.</b> Radyolüsent çene lezyonu tespiti için ROC eğrisi .....                                      | 78 |
| <b>Şekil 4.61.</b> Radyolüsent çene lezyonu tespiti için Precision-Recall eğrisi.....                          | 78 |
| <b>Şekil 4.62.</b> Radyopak çene lezyonu tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP).....    | 79 |
| <b>Şekil 4.63.</b> Radyopak çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP).....    | 79 |

|   |    |
|---|----|
| <b>Şekil 4.64.</b> Radyopak çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN).....         | 80 |
| <b>Şekil 4.65.</b> Radyopak çene lezyonu tespiti için ROC eğrisi.....   | 80 |
| <b>Şekil 4.66.</b> Radyopak çene lezyonu tespiti için Precision-Recall eğrisi .....                                 | 81 |
| <b>Şekil 4.67.</b> Mikst görünümlü çene lezyonu tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP) ..... | 81 |
| <b>Şekil 4.68.</b> Mikst görünümlü çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP).....  | 82 |
| <b>Şekil 4.69.</b> Mikst görünümlü çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN) ..... | 82 |
| <b>Şekil 4.70.</b> Mikst görünümlü çene lezyonu tespiti için ROC eğrisi.....  | 83 |
| <b>Şekil 4.71.</b> Mikst görünümlü çene lezyonu tespiti için Precision-Recall eğrisi .....                          | 83 |

## TABLULAR DİZİNİ

| <b><u>Tablo No:</u></b>  | <b><u>Sayfa No:</u></b> |
|--|-------------------------|
| <b>Tablo 3.1.</b> Çürük tespiti için veri seti sınıflaması.....  | 28                      |
| <b>Tablo 3.2.</b> Restoratif dolgu materyali tespiti için veri seti sınıflaması.....                     | 29                      |
| <b>Tablo 3.3.</b> Kök kanal dolgusu tespiti için veri seti sınıflaması.....                              | 30                      |
| <b>Tablo 3.4.</b> Dental implant tespiti için veri seti sınıflaması.....                                 | 31                      |
| <b>Tablo 3.5.</b> İmplant destekli kuron tespiti için veri seti sınıflaması.....                         | 32                      |
| <b>Tablo 3.6.</b> Kuron tespiti için veri seti sınıflaması.....  | 33                      |
| <b>Tablo 3.7.</b> Pontik tespiti için veri seti sınıflaması.....   | 34                      |
| <b>Tablo 3.8.</b> Gömülü diş tespiti için veri seti sınıflaması.....                                     | 35                      |
| <b>Tablo 3.9.</b> Sürnümerer diş tespiti için veri seti sınıflaması.....                                 | 36                      |
| <b>Tablo 3.10.</b> Rezidüel diş kökü tespiti için veri seti sınıflaması.....                             | 37                      |
| <b>Tablo 3.11.</b> Osteosklerotik alan tespiti için veri seti sınıflaması.....                           | 38                      |
| <b>Tablo 3.12.</b> Periapikal lezyon tespiti için veri seti sınıflaması.....                             | 39                      |
| <b>Tablo 3.13.</b> Radyolüsent çene lezyonu tespiti için veri seti sınıflaması.....                      | 40                      |
| <b>Tablo 3.14.</b> Radyopak çene lezyonu için veri seti sınıflaması.....                                 | 41                      |
| <b>Tablo 3.15.</b> Mikst görünümlü çene lezyonu için veri seti sınıflaması.....                          | 42                      |
| <b>Tablo 3.16.</b> Modelin başarısını değerlendirmek için kullanılan ön hesaplamaların açıklaması.....   | 44                      |
| <b>Tablo 3.17.</b> TP, FP ve FN hesaplandıktan sonra duyarlılık, kesinlik ve F1 skoru hesaplamaları..... | 44                      |

|   |    |
|---|----|
| <b>Tablo 4.1.</b> Mask R-CNN modelinin gerek pozitif (TP), yanlış pozitif (FP), yanlış negatif (FN) deęerleri..... | 46 |
| <b>Tablo 4.2.</b> Mask R-CNN modelinin duyarlılık, kesinlik, F1 skoru deęerleri.....                                | 47 |
| <b>Tablo 4.3.</b> Modellerin AUC deęerleri.....   | 48 |



# 1. GİRİŞ

Yapay zekâ (YZ) bir makinenin akıllı insan davranışını taklit etme, problem çözme, nesne ve kelime tanıma, karar verme gibi karmaşık görevleri yerine getirme becerisi olarak ifade edilir. Teknolojinin etkilediği birçok alanda olduğu gibi sağlık alanında, oral ve maksillofasiyal radyolojide de güncel ve popüler olan konulardan birisi de yapay zekâdır.<sup>1</sup> Yapay zekânın önemli avantajlarından birisi geniş veri setleri sayesinde devamlı gelişip güncellenebilmesidir.<sup>2</sup> Teşhis ve tedavi sürecinin hızlanabilmesine yardımcı olabilmek için radyoloji alanında büyük veri setlerinin elde edilebilir olması nedeniyle yapay zekâ için birçok veri toplanabilir.<sup>3</sup>

Hekimlere medikal ve dental görüntüleme yardımcı olmak adına bilgisayar destekli sistemler geliştirilmiştir. Derin öğrenme sistemleri, insanların önceden yorumlamasına ihtiyaç duymadan verilerdeki bileşenleri otomatik olarak öğrenebilir. Evrişimli sinir ağları, tıbbi görüntüleme en sık tercih edilen derin öğrenme mimarileridir. Evrişimli sinir ağları, orijinal piksel bilgilerini kullanarak görüntü özelliklerini otomatik olarak çıkarabilir ve çoğunlukla dental görüntüleme kullanılır.<sup>4</sup>

Doğru tanı koyabilmek için hasta öyküsü ile birlikte klinik ve radyolojik muayenenin bir bütün olarak değerlendirilmesinin yanında hekimin klinik bilgi ve tecrübesi ile gelişen teknolojiye uyum sağlayıp teknolojiden yararlanabilmesi önemlidir. Radyolojik muayene tanısal diş hekimliğinde önemli bir yere sahiptir.<sup>1</sup> Konik Işınlı Bilgisayarlı Tomografinin (KIBT) son yıllarda maksillofasiyal görüntüleme kullanımını giderek artmaktadır. KIBT, geleneksel iki boyutlu (2D) radyograflara göre kemik ve diş yapılarında bozulma ve süperpozisyon olmadan yüksek çözünürlüklü üç boyutlu (3D) görüntüler sağlar. Diş hekimleri için KIBT görüntülemeye ulaşımın artması, diş hekimliği

uygulamalarında 2D görüntülemeden 3D görüntülemeye geçişe izin vermektedir.<sup>5</sup> Mesleğimize ait yenilikçi yazılım teknolojileri devamlı olarak geliştirilmektedir. Bilgisayar okuryazarlığının artması ve hekimlerin zamanı verimli kullanabilmesi gibi nedenlerle radyoloji alanında gelişmelerin devam edeceği ve KIBT kullanımı sıklığının artacağı tahmin edilmektedir.<sup>6</sup> Bu çalışma, evrişimli sinir ağı temelli algoritmalar kullanılarak geliştirilen yapay zekâ modellerinin, KIBT görüntülerinin değerlendirilmesindeki başarısını değerlendirmeyi amaçlamaktadır.



## 2. GENEL BİLGİLER

### 2.1. Konik Işınlı Bilgisayarlı Tomografi (KIBT)

Diş hekimliğinde tanısal değerlendirmede radyoloji önemli bir yere sahiptir. Konvansiyonel radyograflar birçok klinik durumun değerlendirilmesinde yeterli olmasına rağmen bazı durumlarda 3D görüntüleme, teşhis ve tanıda hekimlere yardımcı olmaktadır. Maliyet, ulaşılabilirlik, radyasyon dozu gibi nedenlerle ileri görüntülemenin kullanımı sınırlıdır. Ancak KIBT'nin kullanılmaya geçilmesi ile 3D görüntüleme hekimlerin talebine karşılık bulması konusunda avantajdır.<sup>7</sup> İki boyutlu dedektör üzerine 3D konik X ışını demetinin yönlendirilmesi prensibiyle çalışan bir görüntüleme yöntemidir.<sup>8</sup> KIBT, izotropik çözünürlük ve yüksek boyutsal doğruluk ile maksillofasiyal bölgede kemik ve dental yapıların 3D hacimsel görüntülenmesini sağlar.<sup>9</sup> KIBT görüntülemesinin çözünürlüğü, hacimsel veri setinden üretilen bireysel hacim elemanları veya vokseller tarafından belirlenir. Vokseller küboid şeklindedir ve 0.125 mm kadar küçük olabilirler. Aksiyel, sagittal ve koronal düzlemlerde seri kesit görüntülerden, kalın veya ince, düzlemsel veya eğri rekonstrüksiyonlar çıkarabilir. Bununla birlikte kemik veya yumuşak doku yüzeylerinin gerçek 3D görüntüleri oluşturulabilir.<sup>10,11</sup> KIBT ilk olarak 1982'de Mayo Klinik Biyodinamik Araştırmaları Laboratuvarı'nda radyoterapi, anjiyografi ve mamografi uygulamalarında kullanılmıştır.<sup>12</sup> Diş hekimliğinde ilk olarak 1995 yılında maksillofasiyal bölge için özel bir KIBT sistemi geliştirilmiştir<sup>13</sup>. Avrupa'da ilk ticari KIBT cihazı, 1999 yılında tanıtılan "NewTom" isimli cihazdır.<sup>14</sup> KIBT görüntülemenin diş hekimliğinde kullanım alanı geniş olmakla beraber özellikle aşağıdaki alanlarda faydalı olduğu belirtilmiştir:

- Çene patolojilerinin araştırılması (kistler, tümörler ve fibro-osseöz lezyonlar)


- Paranasal sinüslerin incelenmesi
- Temporomandibular eklem (TME) kemik bileşenlerinin görüntülenmesi
- Preoperatif ve postoperatif implant değerlendirilmesi
- Ortodontik değerlendirme (diş gelişimi ve iskeletsel değerlendirme)
- Yirmi yaş dişlerinin değerlendirilmesi ve inferior alveolar kanalla ilişkisinin değerlendirilmesi
- Yüz travmasının değerlendirilmesi
- Endodontik tedavilerde dişin kök kanal morfolojisinin incelenmesi<sup>15</sup>

KIBT, tıbbi bilgisayarlı tomografi (BT) ile karşılaştırıldığında birçok avantaja sahiptir. Bunlar radyasyon dozunda %98 azalma, ışın alan bölgenin azaltılması, hızlı tarama süresi (10 ile 40 saniye arasında), görüntü çözünürlüğünün daha iyi olması, metalik restorasyonların oluşturduğu artefaktların daha az olması olarak sıralanabilir.<sup>15</sup>

## **2.2. Yapay Zekâ Nedir?**

Yapay zekâ ile ilgili ilk bilgiler 1940'lara dayanmaktadır. McCulloch ve Pitts tarafından 1943 senesinde "Beynin Boolean Devre Modeli" geliştirilmiştir. Modelde belli varsayımları kullanıp nöronların çalışma prensibini matematiksel olarak ifade eden bir teoriden bahsedilmektedir. Bu teori, YZ'nin en önemli basamağı olarak kabul edilmektedir. Shannon 1948 yılında bilgisayarların belirli algoritmalar dahilinde karmaşık matematik teoremlerini ispatlamak ve satranç oynamak için kullanılabileceği fikrini açıklamıştır.<sup>16</sup> Bu olayların devamında Alan Turing "Makineler düşünebilir mi?" sorusu ile bir makinenin insan gibi düşünebilmesi ve zeki olabilmesi düşüncesini ortaya atan ilk kişidir. Turing testi olarak adlandırılan yaptığı çalışmada, eğer bir insan etkileşim esnasında bilgisayar ile insan arasındaki farkı anlayamıyorsa bilgisayarı insan

kadar akıllı kabul etmek gerektiği varsayımı ortaya atmıştır.<sup>17,18</sup> Şekil 2.1.'de Turing testi gösterilmiştir.



Şekil 2.1. Turing testi<sup>16</sup>

John McCarthy, 1955 yılında “yapay zekâ” terimini ortaya çıkarmıştır. Bu terimi, makinelerin “akıllı” faaliyetler kapsamına girebilecek görevleri yerine getirme potansiyelini açıklamak nedeniyle seçmiştir. John McCarthy, 1956’da resmi olarak YZ araştırma projesinde olan ünlü bir Dartmouth konferansı düzenlemiştir ve bu konferansta YZ terimi ortaya atılmıştır. Konferans, YZ alanında geniş araştırmaların yapıldığı 1950-1970 yılları arasında önemli bir dönemi etkilemiştir.<sup>19</sup> McCarthy, YZ’yi, “İnsan benzeri zeki makineler özellikle de zeki bilgisayar programları yapma bilimi ve mühendisliği” olarak ifade etmiştir.<sup>20</sup> Richard Bellman adlı bir matematikçi 1978 yılında YZ’yi tanımlarken öğrenme, karar verme, problem çözme ve insan gibi düşünce üretebilme etkinliklerinin otomatik yapılabilmesi olarak ifadesini kullanmıştır. Günümüzde YZ, problem çözme gibi insana ait bilişsel kabiliyetleri taklit edebilen herhangi bir makine veya teknolojiyi ifade eder.<sup>19</sup> Yaşanılan teknolojik gelişmeler ve keşifler toplumlarda yaşam kalitesi üzerine etkili olmuştur. Bu gelişmelerden biri de YZ’dir.<sup>21</sup> YZ, insan

zekâsı gerektiren görevleri yerine getirebilmeyi amaçlayan bilgisayar bilimi alanıdır.<sup>22</sup>

YZ'yi oluşturan temel kavramlar Şekil 2.2.'de verilmiştir.



Şekil 2.2. Yapay zekâyı oluşturan temel kavramlar<sup>19</sup>


### 2.3. Makine Öğrenimi

Makine öğrenimi, YZ'nin bir dalı olarak kabul edilir. Bir veri kümesine ve verilerle ilgili bilgilere makine öğrenmesi algoritması uygulandığında; algoritma eğitim verilerinden öğrenip öğrendiklerini tahmin etmekte kullanabilir. Algoritma sistemi, performansını geliştirerek daha fazla test vakasını doğru şekilde teşhis ederse, görevi öğreniyor olarak kabul edilir.<sup>23</sup>

### 2.4. Yapay Sinir Ağları

Yapay sinir ağları, temel olarak insan beyninin işlevini taklit eden paralel hesaplama modelleridir.<sup>24</sup> Günümüzde yapay sinir ağları birçok bilim alanında doğrusal olmama, uyarlanabilirlik, öğrenme, genelleme, hata toleransı gibi özellikleri sebebiyle yer almıştır.<sup>25</sup> Matematiksel olarak modellenme imkanı olmayan, karışık problemlerin modellenmesi yapay sinir ağları ile mümkündür. Bu ağlar, olayları ve arkasındaki

ilişkileri otomatik olarak öğrenir. Değişen koşullara adapte olur. Ayrıca farklı durumların oluşması halinde tekrar eğitilebilir.<sup>26</sup> Şekil 2.3.'te biyolojik sinir hücresi ve yapay sinir ağının şematik gösterimleri verilmiştir.

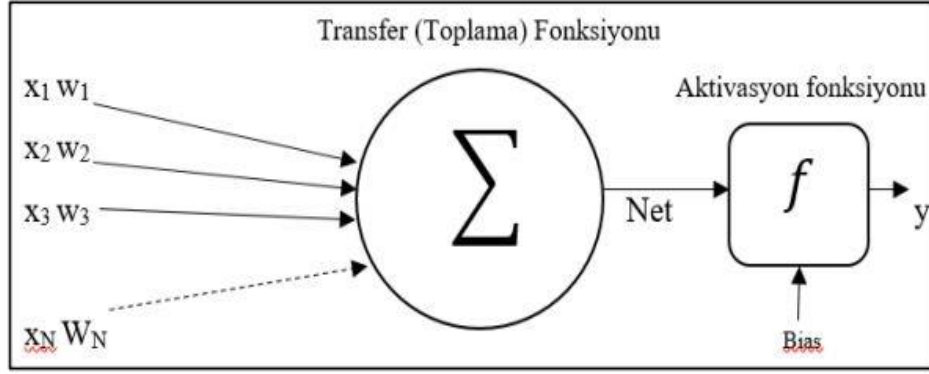


Şekil 2.3. Biyolojik sinir hücresi ve yapay sinir ağı<sup>27</sup>

Bir insanın sinir ağı, birbirine bağlı çok sayıda nöron içerir.<sup>24</sup> Bir nöron hücre gövdesi, dendritler ve akson bileşenlerinden oluşmaktadır. Dendritler hücrelerden aldığı bilgiyi hücre gövdesine iletir. Aksonlar ise bilgiyi hücreden dışarı taşımaktadır. Nöronlar arasında öğrenmeyi sağlayan sinaptik bağlantılar bulunmaktadır. İnsanlar doğdukları zamandan itibaren devamlı öğrenmektedirler. Yeni bilgiler öğrenildikçe nöronlar arasında yeni bağlantılar oluşur.<sup>26</sup> Yapay sinir ağı, biyolojik sinir ağlarına benzetilen bilgi işlem sistemlerini ifade eder.<sup>24</sup> Yapay bir nöron, doğal nöronun yapısını ve davranışını kopyalamaya uğraşır. Bir nöron, farklı kaynaklardan çok sayıda girdi alırken, tek bir çıktıya sahiptir.<sup>28</sup>

Katmanlı bir yapıda olan yapay sinir ağları giriş, ara (gizli) katman/katmanlar ve çıkış katmanından oluşmaktadır. Şekil 2.4.'te verildiği gibi bir yapay sinir ağı nöronunda girdiler ( $x_1, x_2, x_3, \dots, x_N$ ), ağın öğrenmesi için verilen örneklerdir. Bu girdilere karşılık ağırlık değerleri ( $w_1, w_2, w_3, \dots, w_N$ ) ağ üzerindeki etki değerleridir. Tüm girdiler ağırlık

değerleri ile çarpılarak transfer fonksiyonunda birleşip bias değer de eklendikten sonra aktivasyon fonksiyonundan geçirilmektedir.<sup>29</sup> Girdi katmanından giren bilgiler ile doğru çıktıların üretilmesi için ağırlıkların doğru değerlerde olması gereklidir. Doğru ağırlıkların bulunmasına ağı eğitilmesi denir.<sup>30</sup>



Şekil 2.4. Yapay sinir ağı nöron modeli<sup>29</sup>

Yapay sinir ağlarının çoğunlukla tahmin, sınıflandırma, veri ilişkilendirme, yorumlama ve filtreleme gibi uygulamalarda kullanılması tercih edilmektedir.

- Tahmin: Yapay sinir ağlarının girdi değerinden çıktıları tahmin etmesidir.
- Veri Filtreleme: Toplanan veriler içinden en işe yarayacak verilerin kullanılmasıdır.
- Sınıflandırma: Girdi değerlerini sınıflandırılmasıyla sistemin hızlanmasına yardımcı olur.
- Veri Yorumlama: Önceden eğitilmiş ağ girdilerini analiz edip bir durum karşısında yeni yorumlamalar yapabilmesidir.
- Veri İlişkilendirme: Öğrendiği bilgileri konularla ilişkilendirir, devamında eksikleri tamamlar.<sup>27</sup>

## 2.4.1. Yapay Sinir Ağı Modelleri


Yapay sinir ağı modelleri dört gruba ayrılabilir.<sup>27</sup>

### 2.4.1.1. Tek Katmanlı Algılayıcılar

Tek katmanlı algılayıcılar girdi ve çıktıdan oluşur.<sup>27</sup> En önemli sorunu doğrusal olmayan olayları öğrenememeleridir. Bu yüzden yeni modeller geliştirilmiştir.<sup>30</sup>

### 2.4.1.2. Çok Katmanlı Algılayıcılar


Doğrusal yapıda olmayan birçok nöronun birbirine bağlandığı yapıya denir (Şekil 2.5.).<sup>27</sup> Bu ağlar girdi katmanı, ara katmanlar ve çıktı katmanından oluşur.<sup>30</sup>



Şekil 2.5. Çok katmanlı algılayıcı modeli<sup>27</sup>

### 2.4.1.3. İleri Beslemeli Yapay Sinir Ağları


Bu modelde nöronlar girişten çıkışa uzanan düzenli katmanlar halindedir. Bir katmandan yalnızca kendinden sonraki katmanlara bağ bulunmaktadır (Şekil 2.6.). Giriş katmanına gelen bilgiler değiştirilmeden gizli katmana ulaştırılır. Sonrasında çıkış katmanında işlenir ve dışarı aktarılır.<sup>27</sup> İleri beslemeli sinir ağları yaygın kullanım alanına sahiptir.<sup>31</sup>



Şekil 2.6. İleri beslemeli ağ yapısı<sup>27</sup>

### 2.4.1.4. Geri Beslemeli Yapay Sinir Ağları

Veri akışı tek yönlü olmayıp hem ileriye hem geriye doğru sağlanır (Şekil 2.7.). Geri besleme, aynı veya farklı katmanlardaki nöronlar arasında olabilir.<sup>32</sup> Geri beslemeli yapay sinir ağları doğrusal olmayan dinamik bir özellik göstermektedir.<sup>27</sup>



Şekil 2.7. Geri beslemeli ağ yapısı<sup>27</sup>

## 2.5. Derin Öğrenme


Derin öğrenme, 1980 yıllarında sinir ağı araştırmalarından ortaya çıkan bir çeşit makine öğrenimidir. Derin öğrenme ile makine öğreniminin ortak stratejisi verileri kullanan öğrenme modellerini içermesidir. Ancak derin öğrenme sistemlerinin makine öğrenimi modellerinden farkı, büyük verilerden yüksek düzeyde soyutlamalar ve karmaşık özellikler oluşturmalarıdır.<sup>33</sup> Temsil öğrenimi, bir makinenin ham verilerle beslenmesini ve algılama ya da sınıflandırma için gerekli temsilleri otomatik olarak keşfetmesini sağlayan yöntemdir.<sup>34</sup> Derin öğrenme, girdi özelliklerini bir çıktıya eşlemek için temsili öğrenmeyi kullanır. Bu işlem, her biri birden çok nöron içeren birden çok bağlantılı katman içinde gerçekleşir. Nöronlar, girdi özellikleri ile çıktı arasındaki ilişkiyi öğrenmek için tasarlanmış matematiksel bir işlem birimidir.<sup>35</sup>

Derin öğrenme günümüzde, problemlerin çözümünde elde ettiği yüksek doğruluk sayesinde görüntü ve ses analizi, robotik, otonom araçlar, gen analizleri, kanser teşhisleri ve sanal gerçeklik vb. alanlarda kullanılmaktadır.<sup>36</sup>

## 2.5.1. Derin Öğrenme Mimarileri


### 2.5.1.1. Evrişimli Sinir Ağları

İlk olarak LeCun ve arkadaşları tarafından oluşturulan ağ yapısına evrişimli sinir ağı adı verilmiştir.<sup>37</sup> Tıbbi ve dental görüntüleme en çok kullanılan derin öğrenme mimarisidir.<sup>4</sup> Evrişimli sinir ağları çok sayıda katmandan oluşan, geliştirilmesinde görsel korteksten esinlenen bir derin öğrenme yöntemidir. Görsel korteks, görsel alanın belirli bölgelerine duyarlı hücre bölgelerinden oluşmaktadır. Görsel kortekste farklı nöronlar, görüntü üzerinde farklı özelliklere yanıt oluşturmaktadır. Evrişimli sinir ağlarının temelinde belli bir nöron grubunun belli bir göreve sahip olması düşüncesi bulunmaktadır. Bu ağlar ile görüntü sınıflandırma, nesne algılama, doğal dil işleme, konuşma tanıma ve tıbbi görüntü analizi gibi birçok uygulamada başarı sağlanmıştır.<sup>38</sup> Evrişimli sinir ağı mimarisi derin öğrenme kavramına ait temel mimaridir. Sıklıkla görüntü sınıflandırma üzerinde çalışılmaktadır. Evrişimli sinir ağları görüntü sınıflandırma işlemlerinde, Şekil 2.8.'deki gibi pikseller, kenar motiflerini, bu motifler nesne parçalarını ve nesne parçaları ise nesneleri oluşturur.<sup>36</sup> Evrişimli sinir ağlarının genel mimari yapısı Şekil 2.9.'da gösterilmiştir.



**Şekil 2.8.** Evrişimli sinir ağlarının farklı katmanlarda nesne ile ilgili oluşturduğu farklı temsiller<sup>36</sup>

## Evrişimli Sinir Ağlarını Oluşturan Katmanlar



Şekil 2.9. Evrişimli sinir ağının genel mimarisi<sup>36</sup>

### Giriş Katmanı

Verinin ham olarak ağa verildiği ilk katmandır.<sup>36</sup>

### Konvolüsyon Katmanı

Dönüşüm katmanı olarak da adlandırılır. Bu dönüşüm işlemi belirli bir filtrenin tüm görüntü üzerinde dolaştırılmasıyla sağlanmaktadır.<sup>36</sup> İlk evrişim katmanında, kenarlar gibi basit özellikler nöronlar tarafından belirlenirken diğer katmanlara doğru üst düzey karmaşık özellikler algılanır.<sup>39</sup>

### Düzleştirilmiş Doğrusal Birim Katmanı

Bu katmana aktifleştirme katmanı da denir. Doğrusal yapıda olan konvolüsyon katmanından doğrusal olmayan bir şekil oluşturmak için kullanılan katmandır. Böylelikle ağ daha hızlı öğrenme sağlar.<sup>36</sup>

## **Havuzlama Katmanı**

Temel amacı, veri boyutunu (Genişlik x Yükseklik) azaltmaktır. Bu katman sayesinde sonraki ağ katmanları için hesaplama yükü azalır ve sistemin ezberlemesi önlenir.<sup>36,39</sup>

## **Tam Bağlantılı Katman**

Kendinden önceki katmanın tüm alanları bağlı olan katmandır.<sup>36</sup>

## **DropOut Katmanı**

Ağın ezberleme yapmasını önlemek için bu katman kullanılır.<sup>36</sup>


## **Sınıflandırma Katmanı**

Sınıflandırma işleminin yapıldığı katmandır. Katmandaki çıkış değeri, sınıflandırılacak nesne sayısına eşittir.<sup>36</sup>

### **2.5.1.2. Tekrarlayan Sinir Ağları**

İlk olarak basit tekrarlayan ağ, Jeff Elman tarafından tasarlanmıştır.<sup>40</sup> Tekrarlayan sinir ağları, peş peşe oluşan bir dizi yapıda bir sonrasının tahmin edilmesini sağlar. Örnek olarak bir cümlenin kurulması sırasında art arda gelen kelimelerden sonra cümlenin devamında hangi kelimenin geleceğinin tahmin edilmesidir.<sup>37</sup> Konuşma ve dil çevrimleri gibi sıralı girdilerin olduğu görevler için genellikle tekrarlayan sinir ağları kullanılır.<sup>34</sup> Tekrarlayan sinir ağları, sadece ağa giren giriş örneklerini değil aynı zamanda önceki giriş

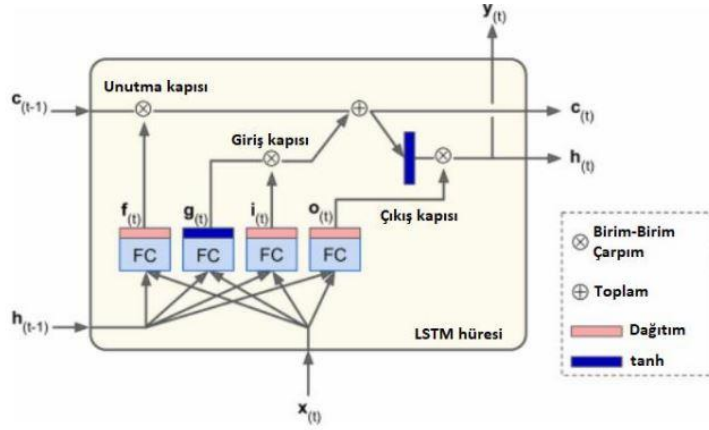
örneklerini de kullanır (Şekil 2.10.). Geleneksel sinir ağlarında girdiler birbirlerinden bağımsız olarak ağa giriş yapar. Fakat tekrarlayan sinir ağlarında verilerin çıktısı önceki hesaplamalarla ilişkilidir.<sup>37</sup>



Şekil 2.10. Tekrarlayan sinir ağı modeli<sup>37</sup>

### 2.5.1.3. Uzun-Kısa Süreli Hafıza (Long Short-Term Memory-LSTM)


LSTM ağları tekrarlayan sinir ağlarına benzemektedir. Fakat LSTM içerisinde öncesini ve girdi bilgisini tutan hafıza hücreleri yer alır. Bu hücreler hangi verinin kalacağına veya hangi verinin sileceğine karar verip mevcut bellek ile giriş verisini birleştirirler.<sup>37</sup> Kısaca LSTM hücresi bir girdiyi tanımayı öğrenebilir, onu uzun süre saklayabilir ve koruyabilir, gerektiğinde bu bilgiyi unutmayı öğrenebilir.<sup>41</sup> Şekil 2.11.'de LTSM ağ yapısı verilmiştir.



Şekil 2.11. LSTM hücresi<sup>41</sup>

#### 2.5.1.4. Sınırlı Boltzmann Makinesi


Girdi setindeki olasılık dağılımlarını öğrenebilen görünür katman ve gizli katmandan oluşan bir sinir ağıdır (Şekil 2.12.). Sınırlı Boltzman Makineleri; sınıflandırma, özellik öğrenimi ve modellemede kullanılır.<sup>42</sup> Ağ yapısında her düğüm bir nöronu ifade eder ve hesaplamalar burada yapılır. Her düğüm gizli katmanda bulunan diğer düğüm ile bağlanır ancak aynı katmanda bulunan düğümler birbirleriyle bağlanmazlar. Katmanlar arasında iletişimin olmaması nedeniyle sınırlı Boltzman makineleri olarak adlandırılır.<sup>37</sup>



Şekil 2.12. Sınırlı Boltzmann makinesi<sup>37</sup>

### 2.5.1.5. Derin İnanç Ağı


Sınırlı Boltzman makinelerinin sırasıyla eğitilerek öğrenilmesiyle gerçekleşir.<sup>37</sup> Görüntü tanıma uygulamalarında kullanılmaktadır.<sup>42</sup> Şekil 2.13.'te derin inanç ağı modeli verilmiştir.



Şekil 2.13. Derin inanç ağı modeli<sup>37</sup>

### 2.5.1.6. Derin Oto-kodlayıcılar

Denetimsiz öğrenme tabanlı makine öğrenmesidir. Derin öğrenme mimarilerinin gelişmesiyle derin öğrenme mimarileri içerisinde yer almaya başlamıştır. Amacı giriş veri kümesini sıkıştırarak az miktarda kayıp ile en iyi öğrenmeyi sağlamaktır. Girdi katmanı, gizli katman ve çıktı katmanından oluşmaktadır. Girdi ve çıktı katmanındaki nöron sayıları eşittir ancak gizli katmandaki nöron sayısı farklılık göstermektedir.<sup>37</sup> Şekil 2.14.'te derin oto-kodlayıcı ağ modeli gösterilmiştir.



Şekil 2.14. Oto-kodlayıcı şeması<sup>37</sup>

## 2.5.2. Derin Öğrenmede Görüntü Segmentasyonu

Görüntünün analizi sağlamak için 3 farklı yöntem kullanılır.<sup>43</sup>

- Sınıflandırma: Bir ögenin hangi sınıfa ait olduğunu tahmin etmeyi içerir.<sup>44</sup>
- Nesne Algılama: Görüntüdeki nesnelere tespit edip çerçeve içine almayı ve lokalizasyonu belirtmeyi ifade eder.<sup>45,46</sup>
- Segmentasyon: Görüntünün parçalarını tanımlamak ve hangi nesneye ait olduklarını tahmin edebilmesidir.<sup>47</sup> Örnek: Bir organın sınırlarını tanıyabilmek.<sup>48</sup>

Resimlerin anlaşılmasında sadeleştirme amacıyla kullanılan segmentasyonun; yüz ve parmak izi tanıma, medikal görüntülerde tümör tespiti, retina görüntülerinden hastalık veya anomali tespit etmek gibi birçok kullanım alanı bulunmaktadır.<sup>49</sup>

Tam evrişimli ağlar, grafik modellenmiş evrişimli modeller, çok ölçekli ve piramit ağ tabanlı modeller, bölge tabanlı evrişimli sinir ağı modelleri (Region-Based Convolutional network-R-CNN), genişletilmiş evrişimli modeller, tekrarlayan sinir ağı tabanlı modeller, dikkat tabanlı modeller, aktif kontur modelleri ile evrişimli modeller, kodlayıcı-kod çözücü tabanlı modeller derin öğrenme tabanlı segmentasyon modellerine örnek olarak verilebilir.<sup>43</sup>

### 2.5.2.1. Bölge Tabanlı Evrişimli Sinir Ağı (Region-Based Convolutional Network R-CNN)

Yüksek nesne algılama doğruluğu sağlayan derin evrişimli sinir ağıdır. R-CNN ağları performansı yüksek ancak yavaş çalışan modeller olması nedeniyle Fast R-CNN, Faster R-CNN gibi hızlı çalışan modeller geliştirilmiştir. Mask R-CNN ise Faster R-CNN ağının türetilmiş farklı bir modelidir. Faster R-CNN, modern nesne algılamada temel

kullanılan sinir ağıdır. Daha sonra, bazı çalışmalar ile bu algılayıcı ağı çeşitli detay problemlerini ele almak için genişletmiş ve bunun yanı sıra yüksek kalitede segmentasyon maskeleri de elde edecek şekilde Mask R-CNN sinir ağı elde edilmiştir. Mask R-CNN modelinin uygulanması ve eğitilmesi kolaydır. Ayrıca, maske dalı yalnızca küçük bir hesaplama yükü ekleyerek hızlı bir sistem ve hızlı deney yapılmasını sağlar.<sup>50</sup> Mask R-CNN modeli; temel olarak nesne algılama, nesne konumu ve segmentasyonu için kullanılırken, aynı zamanda karmaşık ve kalabalık dış görüntüsü segmentasyonunda başarılı sonuçlar verebileceği bildirilmiştir.<sup>51</sup>

### **2.5.2.2. Kodlayıcı-Kod Çözücü Modeller**

Derin öğrenme tabanlı segmentasyon modellerinde yaygın olarak kodlayıcı-kod çözücü modeller kullanılmaktadır.<sup>43</sup> U-Net ve V-Net modelleri, derin öğrenme mimarileri arasında kullanılan modellerdendir.<sup>43,52,53</sup>

### **U-Net ile Görüntü Segmentasyonu**

Evrişimli sinir ağı metotlarından olan U-net, limitli sayıda eğitim verisiyle görüntüleri hassas bir şekilde bölümlere ayırabilen, tıbbi görüntü analizi için geliştirilmiş görüntü bölümlenme tekniğidir. Esnek ve basit özellikleri sayesinde yüksek kalitede segmentasyon sağlamaktadır. Bu özelliklerinden dolayı, tıbbi görüntüleme başarıları yüksektir ve yaygın olarak tercih edilmektedir. U-net çoğunlukla segmentasyon görevlerinde tercih edilmektedir ancak sınıflandırma gibi diğer uygulamalarda kullanılmaktadır. Kullanım potansiyeli tıp ve diğer alanlarda gün geçtikçe artmaktadır.<sup>54</sup>

### 2.5.3. Derin Öğrenme Modelleri

ImageNet tarafından yapılan yarışmada görüntü tanıma için derin öğrenme algoritmaları ortaya konmuştur ve derin öğrenme mimarileri bu sayede daha çok popüler hale gelmiştir. Derin öğrenme mimarileri, nesne tanımada oldukça başarılı sonuçlar vermiştir.<sup>37</sup> ImageNet model yarışmasında başarılı olan evrişimli sinir ağı modelleri arasında; Alex Net, Le Net, ZF Net, VGG-16, GoogLe Net, Microsoft RestNet gibi modeller bulunmaktadır. Bu modeller derin öğrenmeyi anlamak ve geliştirmek için önemlidir.<sup>42</sup>

### 2.5.4. Derin Öğrenme Kütüphaneleri

Derin öğrenmenin yapısında birçok kütüphane bulundurmaktadır, bu kütüphaneler uygulamada kolaylık sağlar. Bu kütüphanelerin her biri farklı işleve sahiptir.<sup>42</sup>

- **Caffe:** Derin öğrenme ve görüntü işleme üzerine oluşturulmuştur. Önceden eğitilmiş modeller içermesi dikkat çeken özelliğidir.<sup>55</sup>
- **Keras:** Tensorflow ile Theano'ya üst katman olarak oluşturulmuştur. Model geliştirmeyi kolaylaştıran bir Python kütüphanesidir.<sup>42</sup>
- **TensorFlow:** Açık kaynak kodlu bir derin öğrenme kütüphanesidir. Sıklıkla görüntü işlemede sayısal işlemler için kullanılır.<sup>55</sup>
- **Torch:** Karışık sorunları basit hale getirip, çözümüyle ilgili algoritmayı esnek ve hızlı olarak hazırlayabilmektedir. Lua ve Python dillerinde çalışan bu kütüphane ile görüntü ve ses işleme, video, resim vb. formatlarda çalışma imkanı bulunmaktadır.<sup>55</sup>
- **MXnet:** Çok dil desteği sunulan kütüphane olarak bilinir ve farklı programlama dillerinde karşılaştırma yapma imkânı sunar.<sup>55</sup>

## 3. MATERYAL VE METOT

### 3.1. Hasta Seçimi

Bu çalışmada veri setini Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı radyografi arşivinden Ocak 2016-Mayıs 2022 tarihleri arasından seçilen 300 adet KIBT görüntüsü oluşturdu. Çalışmamıza 0.400 voksel boyutuna sahip KIBT görüntüleri dahil edilirken görüntü kalitesi kötü olan ve diagnozu etkileyebilecek seviyede artefaktlı radyografik görüntüler (Hareket artefaktı, ışın sertleşmesi artefaktları, tarayıcı ve konik ışınla ilgili artefaktlar), kraniofasiyal sendromu, dudak-damak yarığı, kraniofasiyal bölge kemik hastalıkları olan ve ortognatik cerrahi operasyon geçirmiş hastaların radyografik görüntüleri dahil edilmedi.

Çalışma protokolü Eskişehir Osmangazi Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Komitesi tarafından onaylandı (Karar tarihi ve numarası: 21.09.2021/33). Çalışma Helsinki Bildirgesi'nin ilkelerine göre yapıldı.

### 3.2. Radyografik Veri Setinin Elde Edilmesi

Arşivdeki tüm görüntüler aynı KIBT cihazı (Promax 3D Mid; Planmeca, Helsinki, Finlandiya) kullanılarak elde edildi. Görüntüleme parametreleri: Tüp voltajı 94 kVp, X-ışını tüp akımı 14 mA (miliamper), 360° dönme, tarama süresi 27 saniye ve voksel boyutu 0.400 mm'dir. Çalışmada 300 hastanın KIBT görüntüsü kullanıldı. KIBT görüntüleri Digital Imaging and Communication in Medicine (DICOM) dosyaları şeklinde kaydedildi. DICOM dosyaları <https://pydicom.github.io/datasets> sitesi kullanılarak JPEG (Joint Photographic Experts Group) formatında aksiyel kesit çerçeve görüntülerine

dönüştürüldü. Görüntüler CranioCatch etiketleme yazılımı (Eskişehir, Türkiye) kullanılarak etiketlendi.

### **3.3. Görüntü Değerlendirilmesi**


Etiketleme, bir görüntüdeki alanların tanımlanması ve nesnenin tanımlanan hangi bölgeye ait olduğunun belirlendiği işlemidir. Aksiyel kesit görüntüleri üzerindeki etiketlemeler; CranioCatch (Eskişehir, Türkiye) yazılımı kullanılarak Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Dental YZ Laboratuvarı'nda bulunan Precision 3640 Tower CTO BASE workstation (Intel(R) Xeon(R) W-1250P (6 çekirdek, 12 M önbellek, temel işlemci frekansı 4.1 GHz, Maks Turbo Frekansı 4.8 GHz) DDR4-2666, 64 GB DDR4 (4 X16GB) 2666 MHz UDIMM ECC Hafıza kapasitesi, 256 GB SSD SATA, Nvidia Quadro P620, 2 GB) (Dell, Texas, ABD) ve 27", 1920 x 1080 piksel IPS LCD monitör (Dell, Texas, ABD) kullanılarak gerçekleştirildi.

KIBT aksiyel kesit görüntüleri üzerinde, daha önceden panoramik görüntüler ile de değerlendirilmesi yapılan 15 farklı durum için etiketleme yapıldı. Serbest çizim tekniğine olanak sağlayan poligon yöntemi uygulandı (Şekil 3.1.-3.6.).


#### **3.3.1. YZ modeli geliştirmek için etiketleme yapılan durumlar**

- Çürük
- Restoratif dolgu materyali
- Kök-kanal dolgu materyali
- Dental implant
- İmplant destekli kuron

- Protetik restorasyon materyali-kuron
- Protetik restorasyon materyali-pontik
- Gömülü diş
- Sürnümerer diş
- Rezidüel diş kökü
- Osteosklerotik alan
- Periapikal lezyon
- Radyolüsent çene lezyonu
- Radyopak çene lezyonu
- Mikst görünümlü çene lezyonu




**Şekil 3.1.** Çene kırpması uygulanan görüntü üzerinde çürük, restoratif dolgu materyali ve kuron etiketleme örneği




Şekil 3.2. Çene kırpma işlemi uygulanan görüntü üzerinde kök kanal dolgu materyali ve kuron etiketleme örneği



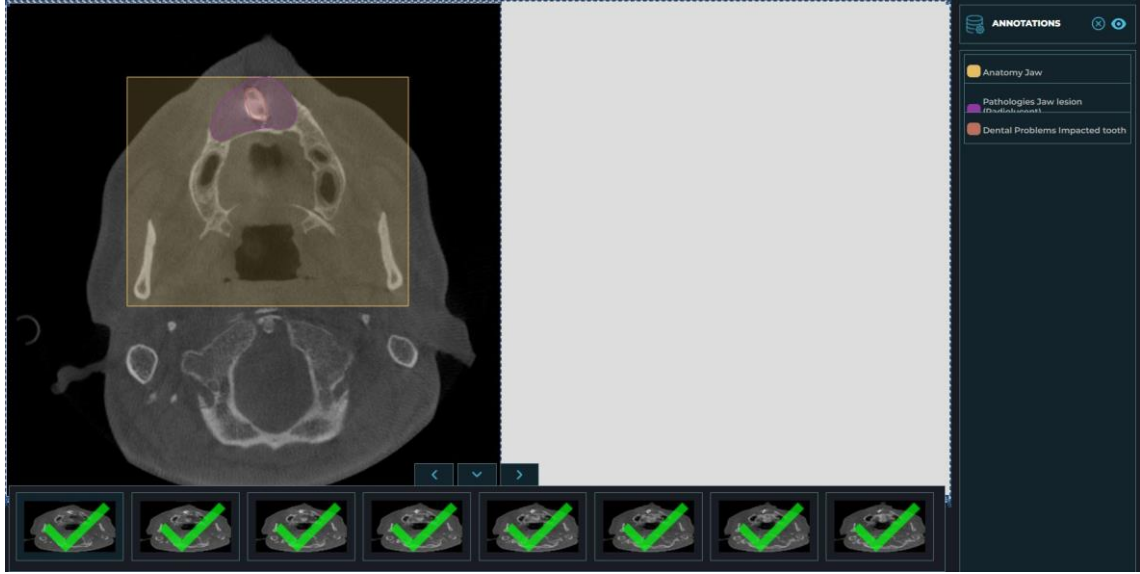
Şekil 3.3. Çene kırpma işlemi uygulanan görüntü üzerinde gömülü diş etiketleme örneği



Şekil 3.4. Çene kırpması işlemi uygulanan görüntü üzerinde mikst görünümlü çene lezyonu etiketleme örneği



Şekil 3.5. Çene kırpması işlemi uygulanan görüntü üzerinde radyolüsent çene lezyonu ve periapikal lezyon etiketleme örneği

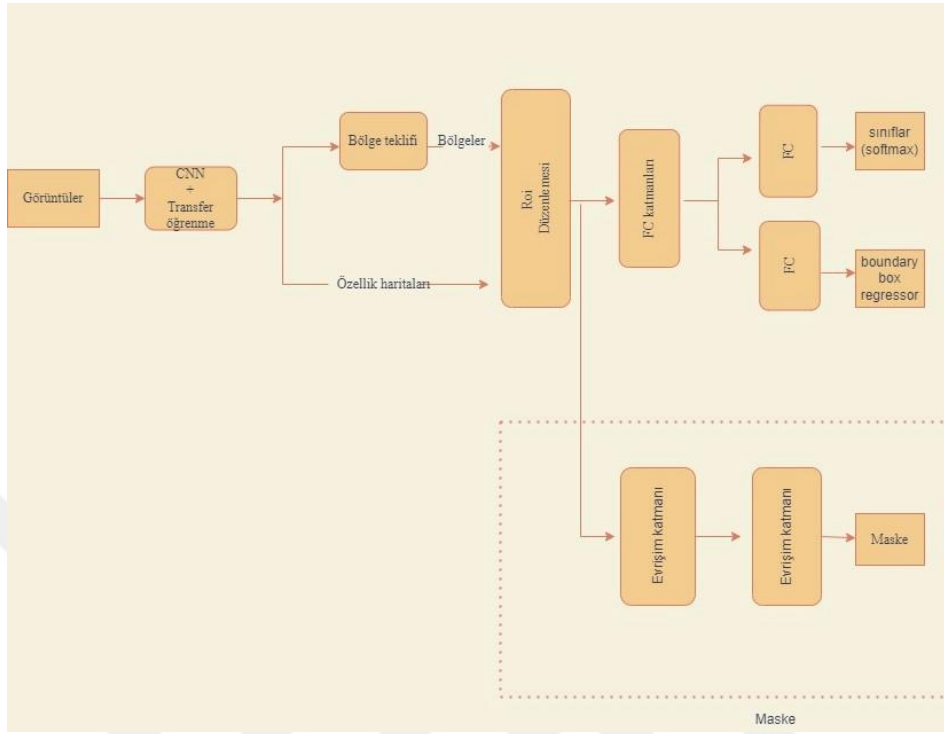


**Şekil 3.6.** Çene kırpma işlemi uygulanan görüntü üzerinde radyolüsent çene lezyonu ve gömülü diş etiketleme örneği

### 3.4. Derin Öğrenme Mimarisi

Derin öğrenme algoritması, Tensorflow kütüphanesi ile uygulanan Mask R-CNN modeli kullanılarak geliştirildi. Mask R-CNN, nesne algılama, nesne lokalizasyonu ve doğal görüntülerin nesne örnek segmentasyonu için geliştirilen teknoloji ile son zamanlarda önerilen bir algoritmadır.<sup>56</sup> Mask R-CNN, Faster R-CNN mimarisinden oluşturulan bir nesne segmentasyon algoritmasıdır. Mask R-CNN algoritması, görüntüdeki nesnelere tespit eder ve her nesnenin üzerinde maske oluşturur. Maskeleme tespit edilen nesnenin sınırları içerisinde bulunan piksellerin segmentasyonu ile gerçekleştirilir.<sup>57</sup> Maskeleme küçük bir hesaplama ile sistemin daha hızlı ilerlemesini sağlar.<sup>58</sup> Görüntü segmentasyonu, görüntülerdeki nesnelere ve sınırları bulmak için kullanılan görüntüyü birden çok segmente ayırma işlemidir.<sup>56</sup> Transfer öğrenme yöntemi olarak Resnet101 algoritması kullanılmıştır. Transfer öğrenme büyük bir veri setiyle eğitilmiş bir ağın öğrendiği bilgileri farklı bir veri kümesi için kullanılmasıdır.<sup>59</sup> Resnet 101, 101 katmandan oluşan bir sinir ağıdır. ImageNet veri tabanında bir milyondan fazla

görüntü üzerinde eğitilen bu ağı kullanılması, bir ağı sıfırdan eğitilmesinden çok daha hızlı ve kolaydır.<sup>60</sup> Şekil 3.7.'de Mask R-CNN mimarisi gösterilmiştir.



Şekil 3.7. Mask R-CNN mimarisi


### 3.5. Model Geliştirilmesi

TensorFlow 1 kitaplığı model geliştirme için kullanıldı. Çalışmamızda modelin eğitimi, 16 GB RAM ve NVIDIA Tesla V100 ekran kartı ile donatılmış bir bilgisayarda gerçekleştirildi.

### 3.6. Eğitim Aşaması

Aksiyal kesit görüntüleri üzerinde çene kırpma işlemi uygulanıp görüntülerde bulunan 15 farklı durum segmente edildi. Veri setleri eğitim, doğrulama ve test veri setleri olmak üzere 3 bölüme ayrıldı. Eğitim ve doğrulama veri setleri optimal evrişimli sinir ağı algoritması ağırlık faktörlerini tahmin etmek ve üretmek için kullanıldı. Modelin başarısı


test veri setiyle kontrol edildi. Veri setinin yaklaşık olarak %10'u test, %10'u doğrulama, %80'i de eğitim veri seti olarak ayrıldı. Eğitim grubundaki aksiyel görüntüler üzerinde etiketlemeler yapıldı. Modellerin tümünün eğitimi 300 epoch (eğitim tur sayısı) yapılarak gerçekleştirildi. Mask R-CNN modeli ile gerçekleştirilen 15 farklı durum için modellerin gelişim aşamalarının diyagramları aşağıdaki şekillerde verilmiştir (Şekil 3.8.-3.22.). Veri seti sınıflandırması aşağıdaki tablolarda gösterilmiştir (Tablo 3.1.-3.15.).



**Şekil 3.8.** Mask R-CNN modeli gerçekleştirilen çürük tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.1.** Çürük tespiti için veri seti sınıflandırması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 2254           | 3249          |
| Doğrulama veri seti | 282            | 426           |
| Test veri seti      | 281            | 396           |



**Şekil 3.9.** Mask R-CNN modeli gerçekleştirilen restoratif dolgu materyali tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.2.** Restoratif dolgu materyali tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 4107           | 8076          |
| Doğrulama veri seti | 513            | 967           |
| Test veri seti      | 513            | 977           |



**Şekil 3.10.** Mask R-CNN modeli gerçekleştirilen kök kanal dolgu materyali tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.3.** Kök kanal dolgusu tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 3810           | 8792          |
| Doğrulama veri seti | 476            | 1037          |
| Test veri seti      | 476            | 1173          |



**Şekil 3.11.** Mask R-CNN modeli gerçekleştirilen dental implant tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.4.** Dental implant tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 424            | 707           |
| Doğrulama veri seti | 53             | 99            |
| Test veri seti      | 52             | 102           |



**Şekil 3.12.** Mask R-CNN modeli gerçekleştirilen implant destekli kuron tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.5.** İmplant destekli kuron tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 232            | 336           |
| Doğrulama veri seti | 29             | 42            |
| Test veri seti      | 28             | 41            |



**Şekil 3.13.** Mask R-CNN modeli gerçekleştirilen kuron tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.6.** Kuron tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 2057           | 4400          |
| Doğrulama veri seti | 257            | 543           |
| Test veri seti      | 257            | 572           |



**Şekil 3.14.** Mask R-CNN modeli gerçekleştirilen pontik tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.7.** Pontik tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 874            | 1264          |
| Doğrulama veri seti | 109            | 153           |
| Test veri seti      | 109            | 160           |



**Şekil 3.15.** Mask R-CNN modeli gerçekleştirilen gömülü dış tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.8.** Gömülü dış tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 3249           | 3618          |
| Doğrulama veri seti | 406            | 462           |
| Test veri seti      | 405            | 525           |



**Şekil 3.16.** Mask R-CNN modeli gerçekleştirilen sürnümerer dış tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.9.** Sürnümerer dış tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 168            | 185           |
| Doğrulama veri seti | 21             | 23            |
| Test veri seti      | 20             | 24            |



**Şekil 3.17.** Mask R-CNN modeli gerçekleştirilen rezidüel diş kökü tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.10.** Rezidüel diş kökü tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 1271           | 2057          |
| Doğrulama veri seti | 159            | 261           |
| Test veri seti      | 158            | 249           |



**Şekil 3.18.** Mask R-CNN modeli gerçekleştirilen osteosklerotik alan tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.11.** Osteosklerotik alan tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 133            | 126           |
| Doğrulama veri seti | 16             | 15            |
| Test veri seti      | 16             | 16            |



**Şekil 3.19.** Mask R-CNN modeli gerçekleştirilen periapikal lezyon tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.12.** Periapikal lezyon tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 1447           | 1689          |
| Doğrulama veri seti | 181            | 211           |
| Test veri seti      | 180            | 236           |



**Şekil 3.20.** Mask R-CNN modeli gerçekleştirilen radyolüsent çene lezyonu tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.13.** Radyolüsent çene lezyonu tespiti için veri seti sınıflaması


|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 5723           | 5379          |
| Doğrulama veri seti | 715            | 684           |
| Test veri seti      | 715            | 750           |



**Şekil 3.21.** Mask R-CNN modeli gerçekleştirilen radyopak çene lezyonu tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.14.** Radyopak çene lezyonu için veri seti sınıflaması

|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 721            | 693           |
| Doğrulama veri seti | 90             | 85            |
| Test veri seti      | 90             | 100           |



**Şekil 3.22.** Mask R-CNN modeli gerçekleştirilen mikst görünümlü çene lezyonu tespiti için modelin gelişim aşamalarının diyagramı

**Tablo 3.15.** Mikst görünümlü çene lezyonu için veri seti sınıflaması

|                     | Görüntü sayısı | Etiket sayısı |
|---------------------|----------------|---------------|
| Eğitim veri seti    | 452            | 421           |
| Doğrulama veri seti | 56             | 52            |
| Test veri seti      | 56             | 56            |

### 3.7. İstatiksel Analiz

Model performanslarını değerlendirmek için karışıklık matrisi kullanıldı. Karışıklık matrisle birlikte Alıcı işlem karakteristiği (Receiver Operating Characteristic Curve-ROC) eğrileri oluşturuldu ve ROC eğrisinin altında kalan alan (Area Under Curve-AUC) hesaplandı.

#### 3.7.1. Karışıklık Matrisi Hesaplama Prosedürü

Karışıklık matrisi, bir sınıflandırma sistemi tarafından yapılan gerçek ve tahmin edilen sınıflandırmalar hakkında bilgi içerir.<sup>61</sup>

Modellerin başarısını değerlendirmek için kullanılan matrisler aşağıdaki gibidir:

**Gerçek pozitif (TP):** Doğru bir şekilde tanımlanan pozitif durumların oranıdır.

**Yanlış pozitif (FP):** Yanlış bir şekilde pozitif olarak sınıflandırılan negatif durumların oranıdır.

**Yanlış negatif (FN):** Yanlış bir şekilde negatif olarak sınıflandırılan pozitif durumların oranıdır.<sup>62</sup>

### 3.8. Performans Değerlendirilmesi

**Duyarlılık:** Doğru olan pozitif ve negatif değerlerin ne ölçüde pozitif olduğunu belirtir.

**Kesinlik:** Pozitif olarak tahmin edilen verilerden ne kadarının doğru tahmin edildiğini belirtir.

**F1 skoru:** Kesinlik ve duyarlılık veri sonuçlarının harmonik ortalamasıdır. F1 skoru, temel gerçek ile tahmin sonucu arasında örtüşen piksellerin kapsamını

yorumlayabilen, segmentasyon değerlendirme metriğidir. Duyarlılık ve kesinlik ölçümlerinin ön hesaplamaları Tablo 3.16.'da gösterilmiştir. Duyarlılık, kesinlik ve F1 skorunun hesaplanması Tablo 3.17.'de gösterilmiştir.<sup>63</sup>

**Tablo 3.16.** Modelin başarısını değerlendirmek için kullanılan ön hesaplamaların açıklaması

|                     |  |
|---------------------|--|
| TP (gerçek pozitif) | Temel gerçek ve tahmin edilen sonuçlar arasında örtüşen bölgeler |
| FP (yanlış pozitif) | Öngörülen sonuçlarda örtüşmeyen bölgeler                         |
| FN (yanlış negatif) | Temel gerçekte örtüşmeyen bölgeler                               |

**Tablo 3.17.** TP, FP ve FN hesaplandıktan sonra duyarlılık, kesinlik ve F1 skoru hesaplamaları

|            |                         |
|------------|-------------------------|
| Duyarlılık | $TP / (TP + FN)$        |
| Kesinlik   | $TP / (TP + FP)$        |
| F1 puanı   | $2TP / (2TP + FP + FN)$ |

**Birleşim üzerinde ortalama kesişim:** Birleşim üzerinden ortalama kesişim (Intersection Over Union- IoU), Pascal VOC 2012'de uygulanan ve doğru pozitifleri, yanlış pozitifleri ve yanlış negatifleri kullanan standart bir değerlendirme yöntemidir. IoU metriği, önerilen yöntemin sonucu ile segmentasyonundaki temel gerçeklik alanı arasındaki örtüşen bölgeyi gösterir.

IoU'yu hesaplamak için aşağıdaki denklem kullanılır:

$$IoU: TP/(TP+FN+FP)$$

F1 puanı ve ortalama IoU, segmentasyonunun performansını 0'dan 1'e kadar değerlendirir ve 1'e yakın bir değer yüksek performansı belirtir.<sup>63</sup>

### 3.9. Alıcı İşlem Karakteristiği (Receiver Operating Characteristic-ROC)

ROC eğrisi; testin ayırt etme performansının tespit edilmesinde, farklı testlerin etkinliklerinin karşılaştırılmasında, uygun pozitiflik eşiğinin belirlenmesinde, laboratuvar sonuçlarının kalitesinin takibinde, farklı uygulayıcıların tanı etkinliklerinin kıyaslanmasında kullanılan duyarlılık ve özgüllük değerlerinin bulunduğu istatistiksel değerlendirme yöntemidir. Bir ROC eğrisinde farklı eşik değerleri için dikey eksen üzerinde doğru pozitiflik (duyarlılık) ve yatay eksen üzerinde yanlış pozitiflik (1-özgüllük) değerleri bulunmaktadır. En faydalı tanı testi, doğru pozitiflik oranı (True positive rate-TPR) yüksek ve yanlış pozitiflik oranı (False positive rate-FPR) düşük olan yani sol üst köşeye yakın olarak geçen eğriyi veren testtir.<sup>64</sup> Testlerin doğru karar verme başarısını değerlendirmek için kullanılan ölçütlerden biri de “ROC Eğrisi Altında Kalan Alan”dır. Eğri altında kalan alan (Area under the curve=AUC) en büyük “1” değerini alabilir.<sup>65</sup>

## 4. BULGULAR

Çalışmamızda KIBT görüntülerinde 15 farklı durum için derin öğrenme yöntemi kullanılarak geliştirilen modellerde otomatik tespit başarısı araştırılmıştır. Her durum için ayrı ayrı performans değerlendirilmesi yapılmıştır. YZ modelleri tarafından belirlenen gerçek pozitif, yanlış pozitif, yanlış negatif değerleri Tablo 4.1.'de verilmiştir. Bu değerlerden hesaplanan duyarlılık, kesinlik ve F1 skorları Tablo 4.2.'de gösterilmiştir. Modellerin başarısını değerlendirmek için ROC eğrisi ve AUC değerleri hesaplanmıştır. AUC değerleri Tablo 4.3.'te verilmiştir. Bilgi erişiminde genellikle kullanılan kesinlik ve hassasiyet eğrisi (P-R eğrisi) ROC eğrilerine alternatif olarak önerilmiştir. Bu eğrilerde amaç sağ üst köşeye yakın olmaktır.<sup>66</sup> Modellerin P-R eğrileri oluşturulmuştur.

**Tablo 4.1.** Mask R-CNN modelinin gerçek pozitif (TP), yanlış pozitif (FP), yanlış negatif (FN) değerleri

|                              | TP   | FP | FN |
|------------------------------|------|----|----|
| Çürük                        | 363  | 8  | 33 |
| Restoratif dolgu materyali   | 950  | 11 | 27 |
| Kök kanal dolgu materyali    | 1157 | 6  | 16 |
| Dental implant               | 102  | 0  | 0  |
| İmplant destekli kuron       | 40   | 0  | 1  |
| Kuron                        | 554  | 18 | 18 |
| Pontik                       | 155  | 7  | 5  |
| Gömülü diş                   | 496  | 15 | 29 |
| Sürünerer diş                | 24   | 7  | 0  |
| Rezidüel diş kökü            | 229  | 6  | 20 |
| Osteosklerotik alan          | 14   | 1  | 2  |
| Periapikal lezyon            | 203  | 12 | 33 |
| Radyolüsent çene lezyonu     | 705  | 43 | 45 |
| Radyopak çene lezyonu        | 96   | 1  | 4  |
| Mikst görünümlü çene lezyonu | 44   | 10 | 12 |

**Tablo 4.2.** Mask R-CNN modelinin duyarlılık, kesinlik, F1 skoru değerleri


|                              | Duyarlılık | Kesinlik | F1 Skoru |
|------------------------------|------------|----------|----------|
| Çürük                        | 0.9166     | 0.9784   | 0.9465   |
| Restoratif dolgu materyali   | 0.9723     | 0.9885   | 0.9803   |
| Kök kanal dolgu materyali    | 0.9863     | 0.9948   | 0.9905   |
| Dental implant               | 1          | 1        | 1        |
| İmplant destekli kuron       | 0.9756     | 1        | 0.9876   |
| Kuron                        | 0.9685     | 0.9685   | 0.9685   |
| Pontik                       | 0.9687     | 0.9567   | 0.9627   |
| Gömülü diş                   | 0.9447     | 0.9706   | 0.9575   |
| Sürnümerer diş               | 1          | 0.7741   | 0.8727   |
| Rezidüel diş kökü            | 0.9196     | 0.9744   | 0.9462   |
| Osteosklerotik alan          | 0.875      | 0.9333   | 0.9032   |
| Periapikal lezyon            | 0.8601     | 0.9441   | 0.9002   |
| Radyolüsent çene lezyonu     | 0.94       | 0.9425   | 0.9412   |
| Radyopak çene lezyonu        | 0.96       | 0.9896   | 0.9746   |
| Mikst görünümlü çene lezyonu | 0.7857     | 0.8148   | 0.8      |

**Tablo 4.3.** Modellerin AUC deęerleri


|                              | AUC deęerleri |
|------------------------------|---------------|
| ürük                        | 0.8679        |
| Restoratif dolgu materyali   | 0.9163        |
| Kök kanal dolgu materyali    | 0.8591        |
| Dental implant               | 0.9203        |
| İmplant destekli kuron       | 0.9023        |
| Kuron                        | 0.8869        |
| Pontik                       | 0.8946        |
| Gömülü diř                   | 0.8682        |
| Sürünerer diř                | 0.9234        |
| Rezidüel diř kökü            | 0.8856        |
| Osteosklerotik alan          | 0.8026        |
| Periapikal lezyon            | 0.8277        |
| Radyolüsent çene lezyonu     | 0.8337        |
| Radyopak çene lezyonu        | 0.8944        |
| Mikst görünümlü çene lezyonu | 0.7961        |

#### 4.1. ürük Tespiti


Geliřtirilen YZ modelinin başarısını belirlemek için 281 görüntü ve 396 adet etiketten oluřan ürük test veri seti kullanılarak yapılan deęerlendirme sonucunda TP, FP, FN deęerleri sırasıyla 363, 8, 33 olarak elde edilmiřtir. Duyarlılık, kesinlik, F1 skoru deęerleri ise sırasıyla 0.9166, 0.9784, 0.9465 olarak hesaplanmıřtır. AUC deęeri 0.8679 olarak hesaplanan modelin gerek-tahmini görüntüleri ile ROC eęrileri ve P-R eęrileri Őekil 4.1.-4.5.'te verilmiřtir.




Şekil 4.1. Çürük tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)




Şekil 4.2. Çürük tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)



Şekil 4.3. Çürük tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)



Şekil 4.4. Çürük tespiti için ROC eğrisi




Şekil 4.5. Çürük tespiti için Precision-Recall eğrisi


## 4.2. Restoratif Dolgu Materyali Tespiti

Geliştirilen YZ modelinin başarısını belirlemek için 513 görüntü ve 977 adet etiketten oluşan restoratif dolgu materyali test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 950, 11, 27 olarak elde


edilmiştir. Duyarlılık, kesinlik, F1 skoru değerleri ise sırasıyla 0.9723, 0.9885, 0.9803 olarak hesaplanmıştır. AUC değeri 0.9163 olarak hesaplanan modelin gerçek-tahmini görüntüleri ile ROC eğrileri ve P-R eğrileri Şekil 4.6.-4.10.'da verilmiştir.




Şekil 4.6. Restoratif dolgu materyali gerçek ve tahmini görüntüler (Gerçek pozitif-TP)




Şekil 4.7. Restoratif dolgu materyali tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)



**Şekil 4.8.** Restoratif dolgu materyali tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)




**Şekil 4.9.** Restoratif dolgu materyali tespiti için ROC eğrisi




**Şekil 4.10.** Restoratif dolgu materyali tespiti için Precision-Recall eğrisi

### 4.3. Kök Kanal Dolgu Materyali Tespiti


Geliştirilen YZ modelinin başarısını belirlemek için 476 görüntü ve 1173 adet etiketten oluşan kök kanal dolgu materyali test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 1157, 6, 16 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru değerleri ise sırasıyla 0.9863, 0.9948, 0.9905 olarak hesaplanmıştır. AUC değeri 0.8591 olarak hesaplanan modelin gerçek-tahmini görüntüleri ile ROC eğrileri ve P-R eğrileri Şekil 4.11.-4.15.'te verilmiştir.




**Şekil 4.11.** Kök kanal dolgusu tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)




**Şekil 4.12.** Kök kanal dolgu materyali tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)



**Şekil 4.13.** Kök kanal dolgu materyali tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)



Şekil 4.14. Kök kanal dolgu materyali tespiti için ROC eğrisi




Şekil 4.15. Kök kanal dolgu materyali tespiti için Precision-Recall eğrisi


#### 4.4. Dental İmplant Tespiti

Geliştirilen YZ modelinin başarısını belirlemek için 52 görüntü ve 102 adet etiketten oluşan dental implant test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 102, 0, 0 olarak elde edilmiştir. Duyarlılık,


kesinlik, F1 skoru deęerleri ise sırasıyla 1, 1, 1 olarak hesaplanmıřtır. AUC deęeri 0.9203 olarak hesaplanan modelin gerek-tahmini grntleri ile ROC eęrileri ve P-R eęrileri Őekil 4.16.-4.18.'de verilmiřtir.



Őekil 4.16. Dental implant tespiti iin gerek ve tahmini grntler (Gerek pozitif-TP)




Őekil 4.17. Dental implant tespiti iin ROC eęrisi




Şekil 4.18. Dental implant tespiti için Precision-Recall eğrisi

#### 4.5. İmplant Destekli Kuron Tespiti


Geliştirilen YZ modelinin başarısını belirlemek için 28 görüntü ve 41 adet etiketten oluşan implant destekli kuron test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 40, 0, 1 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru değerleri ise sırasıyla 0.9756, 1, 0.9876 olarak hesaplanmıştır. AUC değeri 0.9023 olarak hesaplanan modelin gerçek-tahmini görüntüleri ile ROC eğrileri ve P-R eğrileri Şekil 4.19.-4.22.'de verilmiştir.




Şekil 4.19. İmplant destekli kuron tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)



Şekil 4.20. İmplant destekli kuron tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)




Şekil 4.21. İmplant destekli kuron tespiti için ROC eğrisi




**Şekil 4.22.** İmplant destekli kuron tespiti için Precision-Recall eğrisi

#### 4.6. Kuron Tespiti


Geliştirilen YZ modelinin başarısını belirlemek için 257 görüntü ve 572 adet etiketten oluşan kuron test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 554, 18, 18 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru değerleri ise sırasıyla 0.9685, 0.9685, 0.9685 olarak hesaplanmıştır. AUC değeri 0.8869 olarak hesaplanan modelin gerçek-tahmini görüntüleri ile ROC eğrileri ve P-R eğrileri Şekil 4.23.-4.27.'de verilmiştir.




**Şekil 4.23.** Kuron tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)




Şekil 4.24. Kuron tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)



Şekil 4.25. Kuron tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)



Şekil 4.26. Kuron tespiti için ROC eğrisi




Şekil 4.27. Kuron tespiti için Precision-Recall eğrisi


#### 4.7. Pontik Tespiti

Geliştirilen YZ modelinin başarısını belirlemek için 109 görüntü ve 160 adet etiketten oluşan pontik test veri seti kullanılarak yapılan değerlendirme sonucunda TP,


FP, FN deęerleri sırasıyla 155, 7, 5 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru deęerleri ise sırasıyla 0.9687, 0.9567, 0.9627 olarak hesaplanmıştır. AUC deęeri 0.8946 olarak hesaplanan modelin geręek-tahmini grntleri ile ROC eęrileri ve P-R eęrileri Őekil 4.28.-4.32.'de verilmiştir.




Őekil 4.28. Pontik tespiti iin geręek ve tahmini grntler (Geręek pozitif-TP)




Őekil 4.29. Pontik tespiti iin geręek ve tahmini grntler (YanlıŐ pozitif-FP)



Şekil 4.30. Pontik tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)




Şekil 4.31. Pontik tespiti için ROC eğrisi




Şekil 4.32. Pontik tespiti için Precision-Recall eğrisi

#### 4.8. Gömülü Diş Tespiti

Geliştirilen YZ modelinin başarısını belirlemek için 405 görüntü ve 525 adet etiketten oluşan gömülü diş test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 496, 15, 29 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru değerleri ise sırasıyla 0.9447, 0.9706, 0.9575 olarak hesaplanmıştır. AUC değeri 0.8682 olarak hesaplanan modelin gerçek-tahmini görüntüleri ile ROC eğrileri ve P-R eğrileri Şekil 4.33.-4.37.'de verilmiştir.




Şekil 4.33. Gömülü diş tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)




Şekil 4.34. Gömülü diş tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)



Şekil 4.35. Gömülü diş tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)



Şekil 4.36. Gömülü dış tespiti için ROC eğrisi




Şekil 4.37. Gömülü dış tespiti için Precision-Recall eğrisi


#### 4.9. Sürnümerer Dış Tespiti

Geliştirilen YZ modelinin başarısını belirlemek için 20 görüntü ve 24 adet etiketten oluşan sürnümerer dış test veri seti kullanılarak yapılan değerlendirme


sonucunda TP, FP, FN deęerleri sırasıyla 24, 7, 0 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru deęerleri ise sırasıyla 1, 0.7741, 0.8727 olarak hesaplanmıştır. AUC deęeri 0.9234 olarak hesaplanan modelin geręek-tahmini grntleri ile ROC eęrileri ve P-R eęrileri Őekil 4.38.-4.41.'de verilmiştir.




Őekil 4.38. Srnmerer diŐ tespiti iin geręek ve tahmini grntler (Geręek pozitif-TP)



Őekil 4.39. Srnmerer diŐ tespiti iin geręek ve tahmini grntler (YanlıŐ pozitif-FP)



Şekil 4.40. Sürnümerer dış tespiti için ROC eğrisi




Şekil 4.41. Sürnümerer dış tespiti için Precision-Recall eğrisi


#### 4.10. Rezidüel Dış Kökü Tespiti

Geliştirilen YZ modelinin başarısını belirlemek için 158 görüntü ve 249 adet etiketten oluşan rezidüel dış kökü test veri seti kullanılarak yapılan değerlendirme


sonucunda TP, FP, FN deęerleri sırasıyla 229, 6, 20 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru deęerleri ise sırasıyla 0.9196, 0.9744, 0.9462 olarak hesaplanmıştır. AUC deęeri 0.8856 olarak hesaplanan modelin geręek-tahmini grntleri ile ROC eęrileri ve P-R eęrileri Őekil 4.42.-4.46.'da verilmiştir.




Őekil 4.42. Rezidel diŐ kk tespiti iin geręek ve tahmini grntler (Geręek pozitif-TP)




Őekil 4.43. Rezidel diŐ kk tespiti iin geręek ve tahmini grntler (YanlıŐ pozitif-FP)



Şekil 4.44. Rezidüel diş kökü tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)




Şekil 4.45. Rezidüel diş kökü tespiti için ROC eğrisi




**Şekil 4.46.** Rezidüel diş kökü tespiti için Precision-Recall eğrisi

#### 4.11. Osteosklerotik Alan Tespiti


Geliştirilen YZ modelinin başarısını belirlemek için 16 görüntü ve 16 adet etiketten oluşan osteosklerotik alan test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 14, 1, 2 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru değerleri ise sırasıyla 0.875, 0.9333, 0.9032 olarak hesaplanmıştır. AUC değeri 0.8026 olarak hesaplanan modelin gerçek-tahmini görüntüleri ile ROC eğrileri ve P-R eğrileri Şekil 4.47.-4.51.'de verilmiştir.




**Şekil 4.47.** Osteosklerotik alan tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)




**Şekil 4.48.** Osteosklerotik alan tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)



**Şekil 4.49.** Osteosklerotik alan tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)



**Şekil 4.50.** Osteosklerotik alan tespiti için ROC eğrisi




**Şekil 4.51.** Osteosklerotik alan tespiti için Precision-Recall eğrisi


#### 4.12. Periapikal Lezyon Tespiti

Geliştirilen YZ modelinin başarısını belirlemek için 180 görüntü ve 236 adet etiketten oluşan periapikal lezyon test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 203, 12, 33 olarak elde edilmiştir. Duyarlılık,


kesinlik, F1 skoru deęerleri ise sırasıyla 0.8601, 0.9441, 0.9002 olarak hesaplanmıřtır. AUC deęeri 0.8277 olarak hesaplanan modelin gerek-tahmini grntleri ile ROC eęrileri ve P-R eęrileri Őekil 4.52.-4.56.'da verilmiřtir.




**Őekil 4.52.** Periapikal lezyon tespiti iin gerek ve tahmini grntler (Gerek pozitif-TP)




**Őekil 4.53.** Periapikal lezyon tespiti iin gerek ve tahmini grntler (Yanlıř pozitif-FP)



Şekil 4.54. Periapikal lezyon tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)




Şekil 4.55. Periapikal lezyon tespiti için ROC eğrisi




Şekil 4.56. Periapikal lezyon tespiti için Precision-Recall eğrisi

#### 4.13. Radyolüsent Çene Lezyonu Tespiti


Geliştirilen YZ modelinin başarısını belirlemek için 715 görüntü ve 750 adet etiketten oluşan radyolüsent çene lezyonu test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 705, 43, 45 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru değerleri ise sırasıyla 0.94, 0.9425, 0.9412 olarak hesaplanmıştır. AUC değeri 0.8337 olarak hesaplanan modelin gerçek-tahmini görüntüleri ile ROC eğrileri ve P-R eğrileri Şekil 4.57.-4.61.'de verilmiştir.




Şekil 4.57. Radyolüsent çene lezyonu tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)




**Şekil 4.58.** Radyolüsent çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)



**Şekil 4.59.** Radyolüsent çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)



**Şekil 4.60.** Radyolüsent çene lezyonu tespiti için ROC eğrisi




**Şekil 4.61.** Radyolüsent çene lezyonu tespiti için Precision-Recall eğrisi


#### 4.14. Radyopak Çene Lezyonu Tespiti

Geliştirilen YZ modelinin başarısını belirlemek için 90 görüntü ve 100 adet etiketten oluşan radyopak çene lezyonu test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 96, 1, 4 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru değerleri ise sırasıyla 0.96, 0.9896, 0.9746 olarak hesaplanmıştır.


AUC değeri 0.8944 olarak hesaplanan modelin gerçek-tahmini görüntüleri ile ROC eğrileri ve P-R eğrileri Şekil 4.62.-4.66.'da verilmiştir.




**Şekil 4.62.** Radyopak çene lezyonu tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)




**Şekil 4.63.** Radyopak çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)



Şekil 4.64. Radyopak çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)




Şekil 4.65. Radyopak çene lezyonu tespiti için ROC eğrisi



**Şekil 4.66.** Radyopak çene lezyonu tespiti için Precision-Recall eğrisi

#### 4.15. Mikst Görünümlü Çene Lezyonu Tespiti


Geliştirilen YZ modelinin başarısını belirlemek için 56 görüntü ve 56 adet etiketten oluşan mikst görünümlü çene lezyonu test veri seti kullanılarak yapılan değerlendirme sonucunda TP, FP, FN değerleri sırasıyla 44, 10, 12 olarak elde edilmiştir. Duyarlılık, kesinlik, F1 skoru değerleri ise sırasıyla 0.7857, 0.8148, 0.8 olarak hesaplanmıştır. AUC değeri 0.7961 olarak hesaplanan modelin gerçek-tahmini görüntüleri ile ROC eğrileri ve P-R eğrileri Şekil 4.67.-4.71.'de verilmiştir.




**Şekil 4.67.** Mikst görünümlü çene lezyonu tespiti için gerçek ve tahmini görüntüler (Gerçek pozitif-TP)




**Şekil 4.68.** Mikst görümlü çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış pozitif-FP)



**Şekil 4.69.** Mikst görümlü çene lezyonu tespiti için gerçek ve tahmini görüntüler (Yanlış negatif-FN)



Şekil 4.70. Mikst görünlü çene lezyonu tespiti için ROC eğrisi



Şekil 4.71. Mikst görünlü çene lezyonu tespiti için Precision-Recall eğrisi

## 5. TARTIŞMA

Yapay zekâ teknolojileri tıp da dahil olmak üzere birçok alanda gelişerek günlük yaşamı etkileyen önemli başarılar elde etmiştir. Klinik tıp alanında hastalık riskinin tahmin edilmesi, anormalliklerin/patolojilerin tespiti, hastalığın teşhisi ve prognozun değerlendirilmesi için çok sayıda model geliştirilmiştir ve süreç gelişime açıktır. YZ'nin dijital görüntüleme sayesinde radyoloji ile tıp alanına daha kolay erişim sağladığı görülmektedir.<sup>67</sup> Birçok araştırmacı YZ ile diş hekimliği alanında da özellikle oral ve maksillofasiyal radyolojide çalışmalar yapmaktadır.<sup>33</sup> İlk olarak periapikal, panoramik ve sefalometrik radyografları içeren 2D görüntüler, klinik tanıya yardımcı olması için bilgisayar destekli programlar oluşturmak adına kullanıldı.<sup>67</sup>

Periapikal radyograflar üzerinde YZ ile dişlerin tespit ve numaralandırılması,<sup>68,69</sup> çürük tespiti,<sup>70</sup> periapikal periodontitis ve çürük teşhisi,<sup>71</sup> derin çürük ve pulpitisin tespiti,<sup>72</sup> periodontal hastalık tespiti,<sup>73</sup> implant marka tespiti,<sup>74-76</sup> implant çevresindeki kemik kaybının ölçülmesi ve değerlendirilmesi,<sup>77</sup> taşkın restorasyon tespiti,<sup>78</sup> anatomik bölgelerin sınıflandırılması<sup>79</sup> ve dental restorasyonların sınıflandırılması<sup>80</sup> konularında çalışmalar yapılmıştır.

Bitewing radyograflar ile çürük tespiti,<sup>81-84</sup> çürük tespiti ve lezyonun şiddetine göre sınıflandırılması,<sup>85</sup> dişlerin tespit ve numaralandırılması,<sup>4</sup> taşkın restorasyon tespiti,<sup>78</sup> anatomik bölgelerin sınıflandırılması,<sup>79</sup> dental restorasyonların sınıflandırılması<sup>80</sup> gibi YZ çalışmaları bulunmaktadır.

Panoramik radyograflar üzerindeki çalışmalarda günümüzde YZ desteği ile kabul edilebilir sınırlarda teşhislerin yapılabildiği ve modellerin geliştirildiği görülmektedir.<sup>86</sup> Bu çalışmalar YZ ile dişlerin tespiti,<sup>87-90</sup> mandibular 1. molar dişlerin kök morfolojisinin

sınıflandırılması,<sup>91</sup> vertikal kök kırıklarının tespiti,<sup>92</sup> 3. molar dişlerin sürme potansiyelinin tahmin edilmesi,<sup>93</sup> mesiodens tespiti,<sup>94</sup> dental durumların otomatik olarak teşhis edilmesi,<sup>86</sup> mandibular 3. molar diş ile inferior alveolar sinir arasındaki ilişkinin değerlendirilmesi,<sup>95,96</sup> radyasyona bağlı çürüklerin öngörülmesi ve tespiti,<sup>97</sup> ameloblastoma ve odontojenik keratokistin otomatik olarak sınıflandırılması,<sup>98</sup> radyolüsent lezyonların tespiti,<sup>99</sup> osteoporoz tespiti,<sup>100-102</sup> maksiller sinüzitin teşhisi,<sup>103</sup> maksiller sinüs lezyonlarının tespiti,<sup>104</sup> apikal lezyonların segmentasyonu,<sup>105</sup> dental implant markalarının ve tedavi aşamalarının sınıflandırılması,<sup>106</sup> dental implant kırığı tespiti ve sınıflandırılması,<sup>107</sup> TME osteoartritin saptanması,<sup>108</sup> alveolar kemik kaybının belirlenmesi,<sup>109</sup> karotiste ateroskleroz tespiti,<sup>110</sup> mandibula fraktür tespiti,<sup>111</sup> unilateral damak yarığı tespiti,<sup>112</sup> cinsiyet tahmini<sup>113</sup> gibi geniş kapsamlı ve çok çeşitli araştırmaları içermektedir.

YZ destekli programların diş hekimliği radyolojisine sunacağı katkılar göz önüne alındığında KIBT ve diğer 3D görüntülemeler ile ilgili az sayıda çalışma olduğu görülmektedir. Flores ve ark. 2009 yılında yaptıkları çalışmalarında periapikal kistleri granülomdan ayırt etmek için KIBT görüntülerini kullanan bir YZ modeli önermişlerdir. Daha sonra ise KIBT görüntülerine dayalı YZ modelleri geliştirmek isteyen çalışma sayısı artmıştır.<sup>67,114</sup> KIBT görüntüleri ile dişlerin tespit edilmesi ve segmentasyonu,<sup>115-118</sup> periapikal patolojilerin tespiti,<sup>119</sup> gömülü 3. molar dişlerin tespiti,<sup>120</sup> dental implant planlaması,<sup>121</sup> farengeal hava yolu tespiti ve segmentasyonu,<sup>122</sup> mandibular kanal segmentasyonu,<sup>123</sup> TME'de osteoartritin tespiti<sup>124</sup> çalışmaları literatürde yeni bir konu olarak yerini almaktadır.

KIBT, geleneksel radyograflarda karşılaşılan kemik ve diş yapılarında bozulma, süperpozisyon gibi hatalar olmadan dişleri, maksillofasiyal kemik yapıyı ve anatomik oluşumların ilişkisini gösteren yüksek çözünürlüklü 3D görüntülerin oluşturulmasına

imkân sağlamıştır.<sup>119,125</sup> Yapılan bazı çalışmalarda diş hekimlerinin KIBT ile ilgili bilgi eksikliği olduğu ifade edilmiştir ve bu durumun deneyim eksikliği olarak yorumlanabileceği tanımlanmıştır. Bu alanda tanı ve teşhiste yardımcı olabilmek için bilgisayar destekli sistemler geliştirilmiştir.<sup>5,126</sup> Özellikle geniş FOV alanına sahip grafiler göz önünde bulundurulduğunda insan kaynaklı hataları elimine edebilmek günümüz teknolojisinde geliştirilmeye açık bir alan haline gelmiştir. Anatomi ve patolojiyi ayırt edebilen, olası lezyon alanlarına yoğunlaşabilecek, dijital çözümlerle görsellik ve belirginliğin arttırıldığı, karar-destek mekanizması olarak geliştirilecek sistemler medikal ve bilişim alanının dikkatini çekmektedir.

Qiu ve ark.<sup>127</sup> metal artefaktlarından etkilenen KIBT görüntülerinde mandibula segmentasyonu için 3D evrişimli sinir ağı ve tekrarlayan SegUnet'e dayanan kaba ve ince segmentasyondan oluşan bir model önermişlerdir. Modellerini 59 adet KIBT görüntüsü içeren veri seti ile 109 ve 48 adet görüntü içeren 2 BT veri setleriyle değerlendirmişlerdir. U-Net, SegNet, SegUnet, AttUnet, RSegUnet modelleriyle karşılaştırdıklarında önerdikleri algoritmanın bu 3 veri kümesiyle diğer modellere kıyasla farklı görüntüleme teknikleri için daha doğru ve sağlam segmentasyon sonuçları sağlayabileceğini belirtmişlerdir.

Miki ve ark.<sup>116</sup> 52 adet KIBT görüntüsü üzerinde dişlerin tespit edilmesi ve 7 diş tipine göre (santral, lateral, kanin, birinci premolar, ikinci premolar, birinci molar, ikinci molar) sınıflandırılması için AlexNet mimarisi ile YZ modeli geliştirmişlerdir. Eğitilen modelin diş tespiti için %77.4, diş tiplerinin sınıflandırılması için ise %77.1'lik doğruluk oranı gösterdiğini bildirmişlerdir.

Fontenele ve ark.<sup>128</sup> KIBT görüntülerinde diş dolgularının dişlerin otomatik segmentasyonunda performansı etkileyip etkilemeyeceğini 175 KIBT görüntüsüyle

eđitilen bir YZ ađında, en az 1 dolgulu diř bulunan 50 KIBT grntsyle deney grubu ve 24 KIBT grntsyle kontrol grubu oluřturmuřlardır. Deđerlendirme sonucunda YZ modelinin, diř dolgu malzemesinin varlıđından bađımsız olarak diř segmentasyonunu gerekleřtirmek iin yksek dođruluk ve hızlı performans gsterdiđi belirtilmiřtir.

Setzer ve ark.<sup>129</sup> KIBT grntlerinde periapikal lezyonların otomatik tespiti iin 61 adet kk ieren 20 adet KIBT grntsnde U-Net mimarisine dayalı derin đrenme algoritması geliřtirmiřlerdir. alıřmalarının sonucunda lezyon saptama dođruluđu 0.93, zgllk deđer 0.88, pozitif ngr deđer 0.87 ve negatif ngr deđer 0.93 olarak belirtilmiřtir. alıřmalarında etiketlemeleri sagital, koronal, aksiyel kesitlerde periapikal lezyon, diř yapısı, kemik, restoratif materyal ve arka plan olarak yapmıřlardır.

Zheng ve ark.<sup>130</sup> KIBT grntlerinde otomatik lezyon tespiti iin anatomik bilgiyi veriye dayalı Dense U-Net ile birleřtirerek anatomik olarak kısıtlı yeni bir Dense U-net modeli geliřtirerek 20 adet grnt üzerinde yaptıkları alıřmalarında standart Dense U-Net'ten daha iyi bir performans gsterdiđini belirtmiřlerdir. Anatomik alan bilgisi ile btnleřtirilen algoritma iin az sayıda veri ile de olsa modelin performansının iyi olduđu ifade edilmiřtir.

Orhan ve ark.<sup>120</sup> 130 adet gml nc molar diřin bulunduđu KIBT grntleri üzerinde alıřma yapmıřlardır. Bu alıřmada gml diř sayıları, diřlerin kk/kanal sayıları, komřu anatomik yapılarla (inferior alveolar kanal ve maksiller sins) iliřkisi kaydedilmiř ve veriler derin evriřimli sinir ađına (Diagnocat, Inc.) rastgele yklenmiřtir. İnsan gzlemcisi ile YZ uygulaması arasında kaydedilen parametreler Kappa ( $\kappa$ ) analizi kullanılarak deđerlendirilmiřtir. İlgili parametrelerin manuel ve YZ yntemleriyle tespit edilen deđerleri karřılařtırıldıđında 126 diř dođru řekilde tespit edilip numaralandırılmıřtır. Yz on iki diřin gml olduđu, 99 diřin kk sayısı, 82 diřin kanal

sayısı doğru tespit edilmiştir. Inferior alveolar kanalın belirlenmesi ve mandibular gömülü üçüncü molar dişlerle ilişkisinin değerlendirilmesinde ( $\kappa$ : 0.762) iyi bir uyum olduğu bildirilmiştir. Aynı şekilde gömülü maksiller üçüncü molar ve maksiller sinüs ile ilgili olarak ( $\kappa$ : 0.860) mükemmel uyum olduğu bulunmuştur. Maksiller molar kanal sayısı tespiti değerlendirildiğinde insan gözlemci ve YZ arasında orta derecede bir uyum bulunmuştur ( $\kappa$ : 0.424). Bizim çalışmamızda gömülü diş tespiti için segmentasyon yapılmıştır ancak anatomik yapılarla ilişkisi değerlendirilmemiştir. Duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.9447, 0.9706, 0.9575 olarak hesaplanmıştır. Etiketli 525 adet gömülü diştten doğru tespit edilen gömülü diş sayısı 496'dır.

Orhan ve ark.<sup>119</sup> periapikal patolojilerin derin evrişimsel sinir ağı modeli ile tespiti için yaptıkları çalışmalarında 153 adet periapikal patoloji bulunan KIBT görüntüsü kullanmışlardır. Çalışmada lezyonun konumu ve lezyonla ilişkili dişler belirlenip lezyonun hacmi manuel segmentasyon yöntemi (Fujifilm-Synapse 3D yazılımı, Fujifilm Medical Systems) ile hesaplanmıştır. Daha sonra veriler lezyon hacminin hesaplanması için lezyonları tespit etme yaklaşımı U-Net benzeri mimari kullanan derin evrişimli sinir ağı modeline (Diagnocat Inc., San Francisco, CA, ABD) yüklenmiştir. Sistem, 153 periapikal lezyondan 142 periapikal lezyonu tespit etmiş olup bir periapikal lezyonu doğru bir şekilde tespit etmede %92.8 oranında güvenilirlik sağladığı bildirilmiştir. Periapikal lezyonu saptamak için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.89, 0.95, 0.93 olarak hesaplanmıştır. Hacim ölçümlerinin karşılaştırmaları yapıldığında ölçümler arasında anlamlı bir fark bulunamamıştır ( $P>0.05$ ). Bizim çalışmamızda periapikal lezyonun duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.8601, 0.9441, 0.9002 olarak bulunmuştur. Bu çalışmalar daha önce başka bir veri seti ile eğitilmiş bir modelde çalışılmış olmasına rağmen bizim çalışmamızdaki değerlerle benzer sonuçlar elde edilmiştir.

Liu ve ark.<sup>131</sup> mandibular 3. molar dişler ile mandibular kanalın otomatik tespiti ve bunlar arasındaki ilişkinin KIBT ile değerlendirilmesinde bir derin öğrenme yaklaşımı geliştirmek ve doğrulamak amacıyla 254 KIBT görüntüsü üzerinde çalışma yapmışlardır. Mandibular 3. molar dişlerin ve mandibular kanalın tespiti ve segmentasyonunu U-Net mimarisiyle, kanal ve dişler arasındaki ilişkinin sınıflandırılmasını ResNet-34 mimarisi ile gerçekleştirmişlerdir. Otomatik segmentasyon modelini test etmek için zar benzerlik katsayısı (Dice similarity coefficient-DSC), IoU ve piksel doğruluğu kullanılmıştır. Sınıflandırma modellerinin başarısını değerlendirmek için duyarlılık, özgüllük, doğruluk ve karışıklık matrisi hesaplanmıştır. Segmentasyon modülü için değerler, 3. molar dişlerin ortalama DSC değeri 0.9730 ve IoU değeri 0.9606 bulunmuştur. Mandibular kanalın mDSC'si 0.9248 ve mIoU'su 0.9003 olarak tespit edilmiştir. Sınıflandırma modellerinin ise %90.2 oranında duyarlılık, %95.0 oranında özgüllük ve %93.3 oranında doğruluk elde ettiği bildirilmiştir.

Jaskari ve ark.<sup>132</sup> mandibular kanalın otomatik segmentasyonu için farklı tarama cihazlarından alınan 637 KIBT görüntüsü üzerinde çalışma yapmışlardır. Çalışmalarında 3D evrişimli sinir ağı mimarisi U-Net benzeri model kullanmışlardır. DSC değerleri 0.57-0.58 olarak bulunmuştur. Bizim çalışmamızda tek bir cihazdan alınan görüntüler kullanılmıştır. Ancak ileri araştırmalarda modelimizin farklı çekim parametreleri ve farklı cihazlardan elde edilen veri çeşitliliği ile zenginleştirilmesi gerektiği düşünülmektedir.

Lahoud ve ark.<sup>123</sup> 235 KIBT görüntüsünde mandibular kanalı segmente ederek derin öğrenmeye dayalı YZ modeli geliştirmişlerdir. Bu çalışmada, iki evrişimli sinir ağı birlikte çalıştırılmıştır. İlk ağ, mandibular kanalın kaba bir segmentasyonunu gerçekleştirirken ikinci ağ kaba segmentasyonun etrafındaki bölge üzerinde ince bir segmentasyon gerçekleştirmiştir. Çalışmada 3D U-Net mimarisi tercih edilmiştir ve mandibular kanalın segmentasyonu için YZ algoritmasının başarılı bir şekilde

uygulandığı bildirilmiştir. Kesinlik, duyarlılık ve doğruluk sırasıyla 0,782 ( $\pm$  0,121), 0,792 ( $\pm$  0,108) ve 0,99 ( $\pm$   $7,64 \times 10^{-05}$ ) değerlerinde bulunmuştur. Otomatik YZ segmentasyonu için toplam süre, manuel segmentasyondan 107 kat daha hızlı ölçülmüştür. Bu bulgu dijital çözümlerle belirgin miktarda zaman tasarrufu sağlanacağına göstergesi olarak kabul edilebilir.

Ezhov ve ark.<sup>5</sup> KIBT görüntülerinde YZ destekli bir sistemin klinik performansını değerlendiren bir çalışmaları mevcuttur. Mevcut çalışmada 1346 KIBT görüntüsü ve Diagnocat YZ sistemi kullanılmıştır. Model geliştirilmesinden sonra YZ sisteminin tanı koyma performansı ölçülmüştür. Sistemin klinik değerlendirmesine 24 diş hekimi katılmış olup 30 KIBT taraması iki grup diş hekimi tarafından incelenmiştir. Diagnocat sisteminden yardım alan ve almayan grupların genel duyarlılık ve özgüllük sonuçları hesaplanıp karşılaştırılmıştır. Yardım alan ve yardım almayan gruplar için genel duyarlılık ve özgüllük sonuçları, tüm koşulların toplamı olarak hesaplanmıştır. YZ destekli grubun değerlendirme süresinin daha kısa olduğu ifade edilip başarısının daha iyi olduğunu ortaya koymuşlardır. Çalışmada Diagnocat YZ sisteminin tanı koyma performansının değerlendirilmesi için ölçülen duyarlılık değerlerinin, bizim çalışmamızla ortak olan parametreler için kıyaslandığında Diagnocat YZ sistemi için değerler kuron 0.9546, çürük 0.7285, kök kanal tedavili diş 0.9676, restoratif dolgu materyali 0.9721, gömülü diş 0.9137, dental implant 0.9727, periapikal lezyon 0.8383, pontik 0.9101 olarak bulunmuştur. Bizim çalışmamızda ise duyarlılık değerleri kuron 0.9685, çürük 0.9166, kök kanal dolgu materyali 0.9863, restoratif dolgu materyali 0.9723, gömülü diş 0.9447, dental implant 1, periapikal lezyon 0.8601, pontik 0.9687 olarak bulunmuştur.

Mandibular kanalın otomatik segmentasyonu için yapılan bir başka çalışmada Kwak ve ark.<sup>133</sup> 102 hastanın KIBT görüntüsü üzerinde 2D U-Net, Seg-Net ve 3D U-Net modellerini kullanmışlardır. Sonuçlar değerlendirildiğinde 2D U-Net 0,82'lik global

doğruluk gösterirken 2D SegNet 0,96'lık, 3D U-Net 0,99'lık global doğruluğu göstermiştir.

Jarnstedt ve ark.<sup>134</sup> mandibular kanalın lokalizasyonunun derin öğrenme sistemiyle doğruluğunu değerlendirmek için 982 KIBT görüntüsü ile eğitip 4 farklı radyolog ile 5 tarayıcıdan elde edilen görüntüler üzerinde çalışmışlar ve çalışmada U-Net mimarisini kullanmışlardır. Araştırmacılar derin öğrenme sisteminin kanal lokalizasyonunun tespitinde radyologlardan daha iyi bir performans sergilediğini bildirmişlerdir. Bu çalışmada radyologların uzlaşma sağladığı segmentasyonlar altın standart olarak belirlenmiştir.

Kurt Bayrakdar ve ark.<sup>121</sup> KIBT görüntülerini kullanarak YZ'nin implant planlamasındaki başarısını değerlendirmek için yaptıkları çalışmalarında alveolar kemiklerle ilişkili anatomik yapılar (kanallar/sinüsler/fossalar) ve eksik dişler tespit edilmiştir. Eksik diş bölgelerinde manuel değerlendirme yöntemleriyle kemik yüksekliği ve kalınlığı ölçülmüştür. Tüm dosyalar 3D U-Net mimarisine dayanan önceden eğitilmiş semantik segmentasyon ağı modeline (Diagnocat, Inc.) yüklenip manuel değerlendirme ve YZ yöntemlerinden elde edilen veriler karşılaştırılmıştır. Doğru tespit yüzdesi kanallar için %72.2, sinüsler/fossa için %66.4 bulunmuştur. Eksik diş bölgelerinin %95.3'i doğru tespit edilmiştir. Kemik yüksekliği ölçümlerinde, mandibula premolar bölgesi ile maksilla premolar ve molar bölgelerinden yapılan YZ ve manuel ölçümler arasında istatistiksel olarak anlamlı fark bulunamamıştır ( $p>0.05$ ). Ancak kemik kalınlığı ölçümlerinde, maksilla ve mandibulanın tüm bölgelerinde YZ ve manuel ölçümler arasında istatistiksel olarak anlamlı farklılıklar tespit edilmiştir ( $p<0.001$ ).

Roongruangsilp ve ark.<sup>135</sup> KIBT görüntülerinde maksiller molar bölgede implant planlaması için YZ'nin öğrenme eğrisini değerlendirmek amacıyla Faster R-CNN

algoritması kullanmışlardır. Modelin gelişimini gözlemlemek için bulanıklık, keskinleştirme, renk ve gürültü olmak üzere dört veri büyütme algoritması modele entegre edilmiştir. Çalışma sonucunda kullanılan görüntü sayısının YZ yorumlaması ile olumlu bir şekilde ilişkili olduğu sonucuna varılabileceği ifade edilirken YZ'nin yeteneğini geliştirmeye yönelik veri artırma tekniklerinin tartışmalı olduğu bildirilmiştir.

Sin ve ark.<sup>122</sup> 306 adet KIBT görüntüsünde farengeal hava yolu tespiti için YZ algoritması geliştirmişlerdir. Çalışmada U-Net mimarisi kullanılmıştır. Manuel ölçümler ile otomatik segmentasyon ölçümleri karşılaştırıldığında algoritmanın başarılı olduğu bildirilmiştir.

Zhang ve ark.<sup>136</sup> KIBT görüntülerinde TME segmentasyonu gerçekleştirmek için bir 3D U-Net mimarisine dayalı derin öğrenme algoritması üzerinde 45 TME KIBT görüntüsüyle çalışma yapmışlardır. Önerdikleri yöntemlerini, süper piksel segmentasyon algoritması ve aktif kontur modeli ile karşılaştırmışlardır. Değerlendirme sonucunda 3D U-Net modelinin daha yüksek başarı gösterdiği belirtilmiştir.

Görüntülerin hassas ve hızlı bir şekilde segmente edilmesi için geliştirilen U-Net evrişimli bir ağ mimarisidir.<sup>137</sup> Biyomedikal görüntülerin segmentasyonu için kullanılan U-Net mimarisi, daralma ve genişleme olmak üzere iki ana bölümden oluşmaktadır. Daralma bölümünden gelen özellikler genişleme bölümüne aktarılır. Bu bölümde genişletilerek girdi ile aynı boyutta ve çözünürlükte görüntü elde edilir.<sup>138</sup> Yakın zamanda önerilen 3D U-Net mimarisi ise hacimsel segmentasyon için sıklıkla kullanılmaktadır.<sup>139</sup>

Lee ve ark.<sup>124</sup> TME osteoartritinin otomatik olarak tespit edilmesi için KIBT görüntüleri üzerinde YZ modeli geliştirmişlerdir. Çalışmaya TME rahatsızlığı bulunan 314 hastanın KIBT görüntüsü dahil edilmiştir ve nesne algılama modeli olan tek çekim dedektörü (single-shot detector) ile 3.514 sagittal görüntü eğitilmiştir. Nesne algılama,

görüntüdeki nesnelere tespit edip çerçeve içine almayı ve lokalizasyon belirtmeyi ifade eder.<sup>45,46</sup> Model toplamda 2 set 300 görüntü ile test edilmiştir. İki test seti üzerinden ortalama doğruluk, kesinlik, duyarlılık ve F1 puanı sırasıyla 0.86, 0.85, 0.84 ve 0.84 olarak hesaplanmıştır. Bu çalışmada modellerin eğitiminde segmentasyon yerine nesne algılamanın tercih edilmesinin modellerin başarısını etkilemiş olabileceği düşünülmüştür. Bizim çalışmamızda serbest çizim tekniğine olanak sağlayan poligon yöntemi ile segmentasyon tekniği kullanılmıştır.

Leonardi ve ark.<sup>140</sup> sinonazal kavite ve farengeal hava yolunun tam otomatik segmentasyonunun evrişimli sinir ağı temelinde derin öğrenme tabanlı yaklaşımın doğruluğunu test etmek amacıyla bir çalışma yapmışlardır. KIBT taramalarında sinonazal kavite ve farengeal hava yolunun otomatik segmentasyonu için derin öğrenmeye dayalı modellerin doğru ve görüntü yorumlamakta deneyimli biri kadar performansının yüksek olduğu belirtilmiştir.

Odontojenik keratokistler ile ameloblastomaların KIBT görüntüleri üzerinden operasyon öncesi tanısal doğruluklarla ayırt edebilmesini sağlamak için Chai ve ark.<sup>141</sup> 350 adet odontojenik keratokist ve ameloblastoma içeren KIBT görüntüsü üzerinde Inception V3 algoritması mimarisine dayanan YZ modeli geliştirmişlerdir. Sonuçlar değerlendirildiğinde duyarlılık, özgüllük, doğruluk ve F1 skoru sırasıyla %87.2, %82.1, %84.6 ve %85.0 olarak bulunmuş olup derin öğrenme modelinin bu 2 lezyonun ayırt edilmesindeki başarısının yüksek olduğu bildirilmiştir.

Çalışmamıza tek bir cihazdan elde edilen 0.400 voksel boyutuna sahip 300 adet KIBT görüntüsü dahil edilirken görüntü kalitesi kötü olan ve diagnozu etkileyebilecek seviyede artefaktlı radyografik görüntüler ile kraniofasial sendrom, dudak-damak yarığı, kraniofasial bölge kemik hastalıkları olan ve ortognatik cerrahi operasyon geçirmiş

hastaların radyografik görüntüleri çalışma kapsamına alınmamıştır. Çalışmamızın sınırlamaları aynı cihazdan standart parametreler kullanılarak çekilen ve aynı zamanda dar popülasyonun bulunduğu görüntülerin olmasıdır. Bunlarla birlikte çalışmamızda sadece aksiyel görüntüler üzerinde etiketleme yapılmıştır. Sadece aksiyel kesitler üzerinde etiketleme yapılmasının sebebi aksiyel kesitin 3D görüntü rekonstrüksiyonunda temel değerlendirme düzlemi olmasıdır. Gelecek çalışmalarda tüm kesitler üzerinde yapılan etiketlemelerle, farklı düzlemler üzerinden eğitilmiş YZ modellerinin geliştirilmesi ile klinik kullanımda daha yüksek tanısal değerlendirme kapasitesine sahip YZ modellerinin elde edilmesini sağlayabilir. Çalışmamızda mikst görünümlü çene lezyonlarının birbirinden farklı görüntülere sahip olması, lezyonların içerdiği hiperdens ve hipodens alanların farklı oranlarda dağılım göstermesi gibi nedenlerle eğitilen model üzerinde başarısının diğer durumlara göre daha düşük olduğu düşünülmektedir. Ayrıca çalışmamızda osteosklerotik alan-radyopak lezyon ve pontik-kuron-implant destekli kuron gibi benzer görüntülere sahip yapıların ayrı sınıflar altında detaylandırılarak YZ modellerinin geliştirilmesi, klinik kullanımda kullanılabilen daha kapsamlı sınıflamalar yapabilen YZ modelleri geliştirmek amacı taşımaktadır. Bunlara ek olarak, YZ destekli anatomi çalışmaları yapmak YZ'nin patolojiyi ayırt etmesinde fayda sağlayabilir. Ancak tüm sınırlamalar dahilinde çalışmamız umut verici sonuçlar elde etmiştir. Farklı cihazlardan, farklı çekim parametreleri ile elde edilen görüntülerin kullanılması, veri setinin genişletilip daha fazla vakayla algoritmaların eğitilmesi, farklı durumlar için geliştirilen modellerdeki veri seti sayılarının eşit dağılımı YZ'nin daha etkili sonuçlar vermesini sağlayabilir.

## 6. SONUÇLAR VE ÖNERİLER

Çalışmamızın duyarlılık, kesinlik ve F1 skoru değerlerine baktığımızda mikst görünümlü çene lezyonu için tüm değerler, osteosklerotik alan ve periapikal lezyon için duyarlılık değerleri, sürnümerer diş için kesinlik ve F1 skoru değerleri %90'ın altında bulunmuştur. Bu değerler dışındaki tüm sonuçlarımız %90'nın üzerinde elde edilmiştir. Bu çalışmada elde edilen bulgular geliştirdiğimiz YZ modelinin dento-maksillofasiyal radyoloji uygulamalarında hekimlere karar-destek mekanizması olarak yardımcı olacağı konusunda umut vadetmektedir. Günlük iş yükü, insan kaynaklı hatalar, radyolog bulunmayan merkezler göz önünde bulundurulduğunda YZ destekli dijital sistemlerin hekimlere ön fikir verebileceği ve kolaylık sağlayacağı aşikârdır. Sonuç olarak YZ modellerinin radyolojinin tüm alanlarında başarısının artması ile teşhis, tedavi planlaması ve raporlamada hekimlere zaman kazandırıp tespit edilen patolojilere daha geniş zaman ayırılmasını sağlayarak verimliliği arttıracığı düşünülmektedir.

Çalışmamızın sınırlamalarından biri olan veri setine dahil etmediğimiz hasta grupları bir sonraki çalışmalarda dahil edilerek veri seti genişletilebilir. Artan popülasyon ile klinik uygulama açısından daha yararlı sonuçlar elde edilebilir. Farklı cihazlardan, farklı çekim parametreleri ile elde edilen görüntülerin kullanılması klinik uygulama açısından daha başarılı modeller edilmesini sağlayabilir. Aksiyel kesit görüntüleri üzerinden yaptığımız çalışma, tüm kesitler üzerinde uygulanırsa tanı koymada daha yüksek performans elde edilebilir. Etkinlik ve güvenilirliğinin daha iyi tespit edilmesi açısından gözlemci sayısı artırılıp, gözlemciler arası ve YZ modeliyle başarı kıyaslaması yapılabilir.

## KAYNAKLAR

1. Özkesici MY, Yılmaz S. Oral ve maksillofasiyal radyolojide yapay zeka. EUJHS 2021;30(3):346-51.
2. Sağlam H, Tuğba A, Bayrakdar İŞ, Bilgir E, Uğurlu M, Çelik Ö, Orhan K. Diş hekimliğinde yapay zeka. JAIHS 2021;1(2):26-33.
3. Deshmukh SV. Artificial intelligence in dentistry. J Int Clin Dent Res Organ 2018;10(2):47-8.
4. Yasa Y, Çelik Ö, Bayrakdar IS, Pekince A, Orhan K, Akarsu S, Atasoy S, Bilgir E, Odabaş A, Aslan AF. An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs. Acta Odontol Scand 2021;79(4):275-81.
5. Ezhov M, Gusarev M, Golitsyna M, Yates JM, Kushnerev E, Tamimi D, Aksoy S, Shumilov E, Sanders A, Orhan K. Clinically applicable artificial intelligence system for dental diagnosis with CBCT. Sci Rep 2021;11(1):1-16.
6. Miles DA. The future of dental and maxillofacial imaging. Dent Clin North Am 2008;52(4):917-28.
7. Scarfe WC, Farman AG, Sukovic P. Clinical applications of cone-beam computed tomography in dental practice. J Can Dent Assoc 2006;72(1):75-80.
8. Özdede M, Paksoy CS. Konik Işınli Bilgisayarlı Tomografi: Teknik, Çalışma İlkeleri ve Görüntü Oluşumu. Kamburoğlu K, editör. Dentomaksillofasiyal Konik Işınli Bilgisayarlı Tomografi: Temel Prensipler, Teknikler ve Klinik Uygulamalar. 1. Baskı. Ankara: Türkiye Klinikleri;2019;5(1):1-6.

9. Affairs ADACoS. The use of cone-beam computed tomography in dentistry: an advisory statement from the American Dental Association Council on Scientific Affairs. *J Am Dent Assoc* 2012;143(8):899-902.
10. Scarfe WC, Farman AG. What is cone-beam CT and how does it work? *Dent Clin of North Am* 2008;52(4):707-30.
11. White SC, Pharoah MJ. The evolution and application of dental maxillofacial imaging modalities. *Dent Clin North Am* 2008;52(4):689-705.
12. Kamburođlu K, Acar B, Yakar EN, Paksoy CS. Dentomaksillofasiyal Konik Iřın Demetli Bilgisayarlı Tomografi Bölüm 1: Temel Prensipler. *ADO Klinik Bilimler Dergisi* 2012;6(1):1125-36.
13. Angelopoulos C, Scarfe WC, Farman AG. A comparison of maxillofacial CBCT and medical CT. *Atlas Oral Maxillofac Surg Clin North Am* 2012;20(1):1-17.
14. Scarfe WC, Li Z, Aboelmaaty W, Scott SA, Farman AG. Maxillofacial cone beam computed tomography: essence, elements and steps to interpretation. *Aust Dent J* 2012;57:46-60.
15. Macleod I, Heath N. Cone-beam computed tomography (CBCT) in dental practice. *Dent Update* 2008;35(9):590-98.
16. Arslan K. Eğitimde yapay zekâ ve uygulamaları. *BAEBD* 2020;11(1):71-88.
17. Turing AM. Computing machinery and intelligence, Epstein R, Roberts G, Beber G, Parsing the Turing Test. Springer; 2009:23-65.
18. Uzun T. Yapay Zeka ve Sağlık Uygulamaları. *İKÇÜ İİBF Dergisi* 2020;3(1):80-92.
19. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, Sarode SC, Bhandi S. Developments, application, and performance of

- artificial intelligence in dentistry–A systematic review. *J Dent Sci* 2021;16(1):508-22.
20. Moor J. The Dartmouth College artificial intelligence conference: The next fifty years. *AI MAG* 2006;27(4):87-87.
21. Sen D, Chakrabarti R, Chatterjee S, Grewal DS, Manrai K. Artificial intelligence and the radiologist: the future in the Armed Forces Medical Services. *BMJ Mil Health* 2020;166(4):254-56.
22. Chartrand G, Cheng PM, Vorontsov E, Drozdal M, Turcotte S, Pal CJ, Kadoury S, Tang A. Deep learning: a primer for radiologists. *Radiographics* 2017;37(7):2113-31.
23. Erickson BJ, Korfiatis P, Akkus Z, Kline TL. Machine learning for medical imaging. *Radiographics* 2017;37(2):505-15.
24. Dongare A, Kharde R, Kachare AD. Introduction to artificial neural network. *IJEIT* 2012;2(1):189-94.
25. Ergezer H, Dikmen M, Özdemir E. Yapay sinir ağları ve tanıma sistemleri. *PIVOLKA* 2003;2(6):14-17.
26. Yasav M. Yapay sinir ağlarıyla yüz mimiklerinin tanınması. Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı. Yüksek Lisans Tezi, İstanbul: Yıldız Teknik Üniversitesi, 2008.
27. Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi* 2018;6(2):25-36.
28. Kukreja H, Bharath N, Siddesh CS, Kuldeep S. An introduction to artificial neural network. *Int J Adv Res Innov Ideas Edu.* 2016;1:27-30.
29. Başaran E. Timpanik Membran Görüntü Analizi Ve Yapay Zeka Kullanılarak Sanal Otitis Media Tanı Sisteminin Geliştirilmesi. Lisansüstü Eğitim Enstitüsü,

- Bilgisayar Mühendisliği Anabilim Dalı. Doktora Tezi, Karabük: Karabük Üniversitesi, 2020.
30. Öztemel E. Yapay Sinir Ağları. 3. Baskı. Papatya Yayıncılık, İstanbul, 2003.
  31. Serhatlıoğlu S, Hardalaç F. Yapay zeka teknikleri ve radyolojiye uygulanması. Fırat Tıp Dergisi 2009;14(1):1-6.
  32. Asilkan Ö, Irmak S. İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. SDÜ İBB Dergisi 2009;14(2):375-91.
  33. Heo M-S, Kim J-E, Hwang J-J, Han S-S, Kim J-S, Yi W-J, Park I-W. Artificial intelligence in oral and maxillofacial radiology: what is currently possible? Dentomaxillofac Radiol 2021;50(3):20200375.
  34. LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521(7553):436-444.
  35. Georgevici AI, Terblanche M. Neural networks and deep learning: a brief introduction. Intensive Care Med 2019; 45(5):712-14.
  36. Özkan İ, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. GBAD 2017;6(3):85-104.
  37. Doğan F, Türkoğlu İ. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. DÜMF Mühendislik Dergisi 2019;10(2):409-45.
  38. Özcan AR. Eeg işaretlerinde evrişimli sinir ağları ile epileptik nöbet tahmini. Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı. Doktora Tezi, Kocaeli: Kocaeli Üniversitesi, 2020.
  39. Liu YH. Feature extraction and image recognition with convolutional neural networks. Journal of Physics: Conf. Series 1087 (2018) 062032. IOP Publishing, 2018.
  40. Şeker A, Diri B, Balık HH. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. GMBD 2017;3(3):47-64.

41. Yavuz A. Derin öğrenme algoritmaları ile trafik işaret ve levhalarının tanımlanması. Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı. Yüksek Lisans Tezi, Denizli: Pamukkale Üniversitesi, 2021.
42. Gündüz G, Cedimoğlu İH. Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini. SAUCIS 2019;2(1):9-17.
43. Minaee S, Boykov Y, Porikli F, Plaza A, Kehtarnavaz N, Terzopoulos D. Image segmentation using deep learning: A survey. IEEE Trans Pattern Anal Mach Intell 2022; 44(7):3523-42.
44. Chollet F. Xception: Deep learning with depthwise separable convolutions. Proceedings of the IEEE CVPR, 2017, pp. 1251-58.
45. Zhao Z-Q, Zheng P, Xu S-t, Wu X. Object detection with deep learning: A review. IEEE Trans Neural Netw Learn Syst 2019;30(11):3212-32.
46. Redmon J, Farhadi A. YOLO9000: better, faster, stronger. Proceedings of the IEEE CVPR, 2017, pp. 7263-71.
47. Chen L-C, Papandreou G, Kokkinos I, Murphy K, Yuille AL. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. IEEE Trans Pattern Anal Mach Intell 2018;40(4):834-48.
48. Yaji A, Prasad S, Pai A. Artificial intelligence in dento-maxillofacial radiology. ASDS 2019;3(1):116-21.
49. Kökver Y, Ünver HM, Aydoğan Duman E. Retina görüntülerinden kan damarlarının segmentasyonu. Ortadoğu Tıp Dergisi 2017;9(4):198-202.
50. Tekin BY. Bitewing ağız içi radyografik görüntülerde derin öğrenme ile diş segmentasyonu. Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı. Yüksek Lisans Tezi, Karabük: Karabük Üniversitesi, 2021.

51. Zhu G, Piao Z, Kim SC. Tooth detection and segmentation with mask R-CNN. ICAIIC, 2020.
52. Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. International Conference on MICCAI, 2015. pp. 234-41.
53. Milletari F, Navab N, Ahmadi S-A. V-net: Fully convolutional neural networks for volumetric medical image segmentation. 2016 fourth international conference on 3D vision, 2016; 565-71.
54. Koç AB, Akgün D. U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması. EJOSAT 2021(26):407-14.
55. Toğaçar M, Ergen B. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. FÜMBD 2019;31(1):109-21.
56. Kazangirler CB. Elle çizilmiş taslak çizimlerde kullanıcı arabirimi öğelerinin derin örnek segmentasyonu. Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı. Yüksek Lisans Tezi, Karabük: Karabük Üniversitesi, 2021.
57. Güçlü E, Aydın İ, Erhan A. Mask R-CNN Algoritmasını Kullanarak Demiryolu Travers Eksikliklerinin Tespiti İçin Otonom İHA Tasarımı. FÜMBD 2022;34(1):409-20.
58. He K, Gkioxari G, Dollár P, Girshick R. Mask r-cnn. Proceedings of the IEEE ICCV, 2017, pp. 2961-69.
59. Fırıldak K, Talu MF. Evrimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi. Anatolian Science 2019;4(2):88-95.
60. Burgaz M. Derin öğrenme algoritmaları kullanarak insansız hava araçları ile silah tespiti. Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı. Yüksek Lisans Tezi, Batman: Batman Üniversitesi, 2020.

61. Deng X, Liu Q, Deng Y, Mahadevan S. An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Inf Sci* 2016;340:250-61.
62. Santra A, Christy CJ. Genetic algorithm and confusion matrix for document clustering. *IJCSI* 2012;9(1):322.
63. Lee J-H, Han S-S, Kim YH, Lee C, Kim I. Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol* 2020;129(6):635-42.
64. Tomak L, Yüksel B. İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması. *J Exp Clin Med* 2010;27(2):58-65.
65. Kılıç S. Klinik karar vermede ROC analizi. *JMOOD* 2013;3(3):135-140.
66. Davis J, Goadrich M. The relationship between Precision-Recall and ROC curves. *Proceedings of the 23rd ICML, 2006*, pp.233-40.
67. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac Radiol* 2020;49(1):20190107.
68. Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, Lee C-H. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Sci Rep* 2019;9(1):3840.
69. Görürgöz C, Orhan K, Bayrakdar IS, Çelik Ö, Bilgir E, Odabaş A, Aslan AF, Jagtap R. Performance of a convolutional neural network algorithm for tooth detection and numbering on periapical radiographs. *Dentomaxillofac Radiol* 2022;51(3):20210246.

70. Lee J-H, Kim D-H, Jeong S-N, Choi S-H. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent* 2018;77:106-11.
71. Li S, Liu J, Zhou Z, Zhou Z, Wu X, Li Y, Wang S, Liao W, Ying S, Zhao Z. Artificial intelligence for caries and periapical periodontitis detection. *J Dent* 2022:104107.
72. Zheng L, Wang H, Mei L, Chen Q, Zhang Y, Zhang H. Artificial intelligence in digital cariology: A new tool for the diagnosis of deep caries and pulpitis using convolutional neural networks. *Ann Transl Med* 2021;9(9):763.
73. Lee J-H, Kim D-H, Jeong S-N, Choi S-H. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *J Periodontal Implant Sci* 2018;48(2):114-23.
74. Kim J-E, Nam N-E, Shim J-S, Jung Y-H, Cho B-H, Hwang JJ. Transfer learning via deep neural networks for implant fixture system classification using periapical radiographs. *J Clin Med* 2020;9(4):1117.
75. da Mata Santos RP, Vieira Oliveira Prado HE, Aranha Neto IS, Alves de Oliveira GA, Vespasiano Silva AI, Zenobio EG, Ricardo Manzi F. Automated Identification of Dental Implants Using Artificial Intelligence. *Int J Oral Maxillofac Implants* 2021;36(5):918-23.
76. Lee J-H, Jeong S-N. Efficacy of deep convolutional neural network algorithm for the identification and classification of dental implant systems, using panoramic and periapical radiographs: A pilot study. *Medicine* 2020;99(26):20787.
77. Cha J-Y, Yoon H-I, Yeo I-S, Huh K-H, Han J-S. Peri-implant bone loss measurement using a region-based convolutional neural network on dental periapical radiographs. *J Clin Med* 2021;10(5):1009.

78. Fadel HT, Abu-Hammad O, Ghulam OA, Dar-Odeh N. Are Artificial Neural Networks Useful for Predicting Overhanging Dental Restorations? A Cross-sectional Study. *World J Dent* 2020;11(2):100.
79. Kyventidis N, Angelopoulos C. Intraoral radiograph anatomical region classification using neural networks. *Int J Comput Assist Radiol Surg* 2021;16(3):447-55.
80. Karatas O, Cakir NN, Ozsariyildiz SS, Kis HC, Demirbuga S, Gurgan CA. A deep learning approach to dental restoration classification from bitewing and periapical radiographs. *Quintessence Int* 2021;52:568-74.
81. Srivastava MM, Kumar P, Pradhan L, Varadarajan S. Detection of tooth caries in bitewing radiographs using deep learning. *arXiv preprint arXiv:1711.07312* 2017.
82. Lee S, Oh S-i, Jo J, Kang S, Shin Y, Park J-W. Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep* 2021;11(1):1-8.
83. Cantu AG, Gehrung S, Krois J, Chaurasia A, Rossi JG, Gaudin R, Elhennawy K, Schwendicke F. Detecting caries lesions of different radiographic extension on bitewings using deep learning. *J Dent* 2020;100:103425.
84. Estai M, Tennant M, Gebauer D, Brostek A, Vignarajan J, Mehdizadeh M, Saha S. Evaluation of a deep learning system for automatic detection of proximal surface dental caries on bitewing radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol* 2022;134(2):262-70.
85. Moran M, Faria M, Giraldi G, Bastos L, Oliveira L, Conci A. Classification of Approximal Caries in Bitewing Radiographs Using Convolutional Neural Networks. *Sensors* 2021;21(15):5192.

86. Başaran M, Çelik Ö, Bayrakdar IS, Bilgir E, Orhan K, Odabaş A, Aslan AF, Jagtap R. Diagnostic charting of panoramic radiography using deep-learning artificial intelligence system. *Oral Radiol* 2022;38(3):363-69.
87. Leite AF, Gerven AV, Willems H, Beznik T, Lahoud P, Gaeta-Araujo H, Vranckx M, Jacobs R. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clin Oral Investig* 2021;25(4):2257-67.
88. Abdalla-Aslan R, Yeshua T, Kabla D, Leichter I, Nadler C. An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surg Oral Med, Oral Pathol Oral Radiol* 2020;130(5):593-602.
89. Kılıc MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, Akkoca Kaplan F, Sağlam H, Odabaş A, Aslan AF, Yılmaz AB. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofac Radiol* 2021;50(6):20200172.
90. Bilgir E, Bayrakdar İŞ, Çelik Ö, Orhan K, Akkoca F, Sağlam H, Odabaş A, Aslan AF, Ozcetin C, Kılılı M, Rozylo-Kalinowska I. An artificial intelligence approach to automatic tooth detection and numbering in panoramic radiographs. *BMC Med Imaging* 2021;21(1):124.
91. Hiraiwa T, Ariji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, Fujita H, Ariji E. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol* 2019;48(3):20180218.
92. Fukuda M, Inamoto K, Shibata N, Ariji Y, Yanashita Y, Kutsuna S, Nakata K, Katsumata A, Fujita H, Ariji E. Evaluation of an artificial intelligence system for

- detecting vertical root fracture on panoramic radiography. *Oral Radiol* 2020;36(4):337-43.
93. Vranckx M, Van Gerven A, Willems H, Vandemeulebroucke A, Leite AF, Politis C, Jacobs R. Artificial intelligence (AI)-driven molar angulation measurements to predict third molar eruption on panoramic radiographs. *Int J Environ Res Public Health* 2020;17(10):3716.
94. Ha E-G, Jeon KJ, Kim YH, Kim J-Y, Han S-S. Automatic detection of mesiodens on panoramic radiographs using artificial intelligence. *Sci Rep* 2021;11(1):23061.
95. Choi E, Lee S, Jeong E, Shin S, Park H, Youm S, Son Y, Pang K. Artificial intelligence in positioning between mandibular third molar and inferior alveolar nerve on panoramic radiography. *Sci rep* 2022;12(1):1-7.
96. Zhu T, Chen D, Wu F, Zhu F, Zhu H. Artificial Intelligence Model to Detect Real Contact Relationship between Mandibular Third Molars and Inferior Alveolar Nerve Based on Panoramic Radiographs. *Diagnostics* 2021;11(9):1664.
97. De Araujo Faria V, Azimbagirad M, Viani Arruda G, Fernandes Pavoni J, Cezar Felipe J, Dos Santos EMC MF, Murta Junior LO. Prediction of Radiation-Related Dental Caries Through PyRadiomics Features and Artificial Neural Network on Panoramic Radiography. *J Digit Imaging* 2021;34(5):1237-48.
98. Liu Z, Liu J, Zhou Z, Zhang Q, Wu H, Zhai G, Han J. Differential diagnosis of ameloblastoma and odontogenic keratocyst by machine learning of panoramic radiographs. *Int J Comput Assist Radiol Surg* 2021;16(3):415-22.
99. Tajima S, Okamoto Y, Kobayashi T, Kiwaki M, Sonoda C, Tomie K, Saito H, Ishikawa Y, Takayoshi S. Development of an automatic detection model using artificial intelligence for the detection of cyst-like radiolucent lesions of the jaws

- on panoramic radiographs with small training datasets. *J Oral Maxillofac Surg Med Pathol* 2022;34(5):553-60.
100. Hwang JJ, Lee J-H, Han S-S, Kim YH, Jeong H-G, Choi YJ, Park W. Strut analysis for osteoporosis detection model using dental panoramic radiography. *Dentomaxillofac Radiol* 2017;46(7):20170006.
  101. Aliaga I, Vera V, Vera M, García E, Pedrera M, Pajares G. Automatic computation of mandibular indices in dental panoramic radiographs for early osteoporosis detection. *Artif Intell Med* 2020;103:101816.
  102. Lee J-S, Adhikari S, Liu L, Jeong H-G, Kim H, Yoon S-J. Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminary study. *Dentomaxillofac Radiol* 2019;48(1):20170344.
  103. Murata M, Ariji Y, Ohashi Y, Kawai T, Fukuda M, Funakoshi T, Kise Y, Nozawa M, Katsumata A, Fujita H, Ariji E. Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral Radiol* 2019;35(3):301-07.
  104. Kuwana R, Ariji Y, Fukuda M, Kise Y, Nozawa M, Kuwada C, Muramatsu C, Katsumata A, Fujita H, Ariji E. Performance of deep learning object detection technology in the detection and diagnosis of maxillary sinus lesions on panoramic radiographs. *Dentomaxillofac Radiol* 2021;50(1):20200171.
  105. Bayrakdar IS, Orhan K, Çelik Ö, Bilgir E, Sağlam H, Akkoca Kaplan F, Atay Görür S, Odabaş A, Aslan AF, Rozylo-Kalinowska I. A U-Net Approach to Apical Lesion Segmentation on Panoramic Radiographs. *BioMed Res Int* 2022;2022:7035367.

106. Sukegawa S, Yoshii K, Hara T, Matsuyama T, Yamashita K, Nakano K, Takabatake K, Kawai H, Nagatsuka H, Furuki Y. Multi-task deep learning model for classification of dental implant brand and treatment stage using dental panoramic radiograph images. *Biomolecules* 2021;11(6):815.
107. Lee D-W, Kim S-Y, Jeong S-N, Lee J-H. Artificial intelligence in fractured dental implant detection and classification: evaluation using dataset from two dental hospitals. *Diagnostics* 2021;11(2):233.
108. Choi E, Kim D, Lee J-Y, Park H-K. Artificial intelligence in detecting temporomandibular joint osteoarthritis on orthopantomogram. *Sci Rep* 2021;11(1):1-7.
109. Kurt Bayrakdar S, Çelik Ö, Bayrakdar İŞ, Orhan K, Bilgir E, Odabaş A, Aslan AF. Success of artificial intelligence system in determining alveolar bone loss from dental panoramic radiography images. *Cumhuriyet Dent J* 2020;23(4):318-24.
110. Kats L, Vered M, Zlotogorski-Hurvitz A, Harpaz I. Atherosclerotic carotid plaque on panoramic radiographs: neural network detection. *Int J Comput Dent* 2019;22(2):163-69.
111. Son D-M, Yoon Y-A, Kwon H-J, An C-H, Lee S-H. Automatic detection of mandibular fractures in panoramic radiographs using deep learning. *Diagnostics* 2021;11(6):933.
112. Kuwada C, Arijji Y, Kise Y, Funakoshi T, Fukuda M, Kuwada T, Gotoh K, Arijji E. Detection and classification of unilateral cleft alveolus with and without cleft palate on panoramic radiographs using a deep learning system. *Sci Rep* 2021;11(1):1-10.

113. Ortiz A, Costa C, Silva R, Biazevic M, Michel-Crosato E. Sex estimation: Anatomical references on panoramic radiographs using Machine Learning. *Forensic Imaging* 2020;20:200356.
114. Flores A, Rysavy S, Enciso R, Okada K. Non-invasive differential diagnosis of dental periapical lesions in cone-beam CT. *2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro* 2009.
115. Chen Y, Du H, Yun Z, Yang S, Dai Z, Zhong L, Feng Q, Yang W. Automatic segmentation of individual tooth in dental CBCT images from tooth surface map by a multi-task FCN. *IEEE Access* 2020;8:97296-97309.
116. Miki Y, Muramatsu C, Hayashi T, Zhou X, Hara T, Katsumata A, Fujita H. Tooth labeling in cone-beam CT using deep convolutional neural network for forensic identification. *Medical Imaging 2017: Computer-Aided Diagnosis 2017*, p. 101343E.
117. Cui Z, Li C, Wang W. ToothNet: automatic tooth instance segmentation and identification from cone beam CT images. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2019*, pp.6368-77.
118. Rao Y, Wang Y, Meng F, Pu J, Sun J, Wang Q. A symmetric fully convolutional residual network with DCRF for accurate tooth segmentation. *IEEE Access* 2020;8:92028-92038.
119. 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):680-89.
120. Orhan K, Bilgir E, Bayrakdar IS, Ezhov M, Gusarev M, Shumilov E. Evaluation of artificial intelligence for detecting impacted third molars on cone-beam

- computed tomography scans. *J Stomatol Oral Maxillofac Surg* 2021;122(4):333-37.
121. Kurt Bayrakdar S, Orhan K, Bayrakdar IS, Bilgir E, Ezhov M, Gusarev M, Shumilov E. A deep learning approach for dental implant planning in cone-beam computed tomography images. *BMC Med Imaging* 2021;21(1):86.
122. Sin Ç, Akkaya N, Aksoy S, Orhan K, Öz U. A deep learning algorithm proposal to automatic pharyngeal airway detection and segmentation on CBCT images. *Orthod Craniofac Res* 2021;24:117-23.
123. Lahoud P, Diels S, Niclaes L, Van Aelst S, Willems H, Van Gerven A, Quirynen M, Jacobs R. Development and validation of a novel artificial intelligence driven tool for accurate mandibular canal segmentation on CBCT. *J Dent* 2022;116:103891.
124. Lee KS, Kwak HJ, Oh JM, Jha N, Kim YJ, Kim W, Baik UB, Ryu JJ. Automated detection of TMJ osteoarthritis based on artificial intelligence. *J Dent Res* 2020;99(12):1363-67.
125. of Endodontists AA. Use of cone-beam computed tomography in endodontics Joint Position Statement of the American Association of Endodontists and the American Academy of Oral and Maxillofacial Radiology. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod* 2011;111(2):234-37.
126. Reddy RS, Kiran CS, Ramesh T, Kumar BN, Naik RM, Ramya K. Knowledge and attitude of dental fraternity towards cone beam computed tomography in south India—A questionnaire study. *Indian J Dent* 2013;4(2):88-94.
127. Qiu B, van der Wel H, Kraeima J, Glas HH, Guo J, Borra RJH, Witjes MJH, van Ooijen PMA. Mandible Segmentation of Dental CBCT Scans Affected by Metal Artifacts Using Coarse-to-Fine Learning Model. *J Pers Med* 2021;11(6):560.

128. Fontenele RC, do Nascimento Gerhardt M, Willems H, Jacobs R. Can dental fillings affect the performance of an AI-driven innovative tool for automatic tooth segmentation in cone-beam computed tomography: A validation study? *J Dent* 2022;121:103990.
129. Setzer FC, Shi KJ, Zhang Z, Yan H, Yoon H, Mupparapu M, Li J. Artificial intelligence for the computer-aided detection of periapical lesions in cone-beam computed tomographic images. *J Endod* 2020;46(7):987-93.
130. Zheng Z, Yan H, Setzer FC, Shi KJ, Mupparapu M, Li J. Anatomically constrained deep learning for automating dental CBCT segmentation and lesion detection. *IEEE Transactions on Automation Science and Engineering* 2020;18(2):603-14.
131. Liu M-Q, Xu Z-N, Mao W-Y, Li Y, Zhang X-H, Bai H-L, Ding P, Fu K-Y. Deep learning-based evaluation of the relationship between mandibular third molar and mandibular canal on CBCT. *Clin Oral Investig* 2022;26(1):981-91.
132. Jaskari J, Sahlsten J, Järnstedt J, Mehtonen H, Karhu K, Sundqvist O, Hietanen A, Varjonen V, Mattila V, Kaski K. Deep learning method for mandibular canal segmentation in dental cone beam computed tomography volumes. *Sci Rep* 2020;10(1):5842.
133. Kwak GH, Kwak E-J, Song JM, Park HR, Jung Y-H, Cho B-H, Hui P, Hwang JJ. Automatic mandibular canal detection using a deep convolutional neural network. *Sci Rep* 2020;10(1):1-8.
134. Järnstedt J, Sahlsten J, Jaskari J, Kaski K, Mehtonen H, Lin Z, Hietanen A, Sundqvist O, Varjonen V, Mattila V, Prapayasotok S, Nalampang S. Comparison of Deep Learning Segmentation and Multigrader-annotated Mandibular Canals of Multicenter CBCT scans. *arXiv preprint arXiv:2205.13874* 2022.

135. Roongruangsilp P, Khongkhunthian P. The Learning Curve of Artificial Intelligence for Dental Implant Treatment Planning: A Descriptive Study. *Appl Sci* 2021;11(21):10159.
136. Zhang K, Li J, Ma R, Li G. An end-to-end segmentation network for the temporomandibular joints CBCT image based on 3D U-Net. 2020 13th CISP-BMEI 2020.
137. Ozturk O, Saritürk B, Seker DZ. Comparison of Fully Convolutional Networks (FCN) and U-Net for Road Segmentation from High Resolution Imageries. *IJEGEO* 2020;7(3):272-79.
138. Eker AG, Nevcihan D. Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları. *ACIN* 5(2):459-74.
139. Hwang H, Rehman HZU, Lee S. 3D U-Net for skull stripping in brain MRI. *Appl Sci* 2019;9(3):569.
140. Leonardi R, Giudice AL, Farronato M, Ronsivalle V, Allegrini S, Musumeci G, Spampinato C. Fully automatic segmentation of sinonasal cavity and pharyngeal airway based on convolutional neural networks. *Am J Orthod Dentofacial Orthop* 2021;159(6):824-35.
141. Chai Z-K, Mao L, Chen H, Sun T-G, Shen X-M, Liu J, Sun Z-J. Improved Diagnostic Accuracy of Ameloblastoma and Odontogenic Keratocyst on Cone-Beam CT by Artificial Intelligence. *Front Oncol* 2021;11:793417.

## EKLER

### EK-1. ÖZGEÇMİŞ

#### 1. KİŞİSEL BİLGİLER

|   |
|---|
| <b>Adı, Soyadı: Tuğba Arı</b><br>Doğum Tarihi ve Yeri:  |
| <b>Mevcut Görevi: Araştırma Görevlisi</b><br><b>Mevcut Görev Yeri: Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi</b><br><b>Ağız, Diş ve Çene Radyolojisi AD. Meşelik Kampüsü- Eskişehir</b><br>Yazışma Adresi:<br>Telefon:<br>E-posta: |

#### 2. EĞİTİM

| Mezuniyet Yılı | Derecesi | Dereceyi aldığı üniversite | Öğrenim Alanı                 |
|----------------|----------|----------------------------|-------------------------------|
| 2016           | Lisans   | Ankara Üniversitesi        | Diş Hekimliği                 |
| 2020-          | Uzmanlık | Osmangazi Üniversitesi     | Ağız, Diş ve Çene Radyolojisi |

#### 3. AKADEMİK DENEYİM

| Görev Dönemi | Unvan    | Bölüm/Anabilim Dalı           | Üniversite             |
|--------------|----------|-------------------------------|------------------------|
| 2020-        | Arş. Gör | Ağız, Diş ve Çene Radyolojisi | Osmangazi Üniversitesi |

#### 4. ÇALIŞMA ALANLARI

| Çalışma Alanı/Konusu          | Anahtar Sözcükler             |
|-------------------------------|-------------------------------|
| Ağız, Diş ve Çene Radyolojisi | Ağız, Diş ve Çene Radyolojisi |

## 1. SON BEŞ YILDAKİ ÖNEMLİ YAYINLARI

### Kitap Bölümü

- 1- Yaşar F, Arı T. Kanser ve orofasiyal ağrı. Yaşar F, editör. Orofasial Ağrı: Tanı ve Güncel Tedavi Yaklaşımları. 1. Baskı. Ankara: Türkiye Klinikleri; 2021. p.44-50.
- 2- Tuğba Arı, Esra Yeşilova, İbrahim Şevki Bayrakdar, Elif Bilgir. Dentomaksillofasial Radyolojide Karşılaşılan İntra ve Ekstra Kranial Kalsifikasyonlar ile Ossifikasyonlar. Güncel Ağız, Diş, Çene Cerrahisi ve Periodontoloji Çalışmaları, AYBAK, 2021/MART.
- 3- Hande Sağlam, Tuğba Arı, İbrahim Şevki Bayrakdar, Esra Yeşilova, Elif Bilgir. Çene Kemiklerinde Görülen Kistik Lezyonların Tanısı. Sağlık Bilimlerinde Güncel Araştırmalar, IVPE, 2020.

### Ulusal makale

- 1- Sağlam, H., Arı, T., Bayrakdar, İ. Ş., Bilgir, E., Açıkalm, M. F., & Başaran, D. Sert Damakta Mavi Nevus: Olgu Raporu. 7tepe Klinik Dergisi, 17(3), 235-238.

### Derleme

- 1- Sağlam, H., Tuğba, A. R. I., Bayrakdar, İ. Ş., Bilgir, E., Uğurlu, M., Çelik, Ö., & Orhan, K. (2021). Diş Hekimliğinde Yapay Zekâ: Artificial Intelligence In Dentistry. Sağlık Bilimlerinde Yapay Zekâ Dergisi (Journal Of Artificial Intelligence İn Health Sciences) Issn: 2757-9646, 1(2), 26-33.

## **Sözlü Sunu**

- 1- Dental Periapikal Radyografilerin Derin Öğrenme Yöntemine Bağlı Yapay Zekâ Algoritmaları ile Değerlendirilmesi. “II. Uluslararası Sağlıkta Yapay Zekâ Kongresi 2021” 16-18 Nisan. En iyi sözlü bildiri 3.’lük ödülü.



## EK-2. ETİK KURUL ONAYI



T.C.  
ESKİŞEHİR OSMANGAZİ  
ÜNİVERSİTESİ  
Girişimsel Olmayan Klinik Araştırmalar Etik  
Kurul Başkanlığı

Sayı :E-25403353-050.99-248792

12.11.2021

Konu : 2021 - 352 Karar

Sayın Doç. Dr. İbrahim Şevki BAYRAKDAR  
Eskişehir Osmangazi Üniversitesi Diş Hekimliği  
Fakültesi  
Ağız, Diş ve Çene Radyolojisi Anabilim Dalı

Karar Tarihi: 21.09.2021

Karar Sayısı: 33

Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi  
Anabilim Dalı

– Doç. Dr. İbrahim Şevki BAYRAKDAR’ın sorumluluğunda yürütülecek olan **“Konik Işınlı Bilgisayarlı Tomografi Görüntülerinin Yapay Zeka ile Değerlendirilmesi”** başlıklı araştırmanın/çalışmanın gerçekleştirilmesinde etik ve bilimsel açıdan sakınca bulunmadığına karar verilmiştir.

Bilgilerinizi ve gereğini saygı ile rica ederim.

Prof. Dr. Merih ÖZGEN

Kurul Başkanı

Ek: e-imzalı Etik Kurul Kararı

**Bu belge, güvenli elektronik imza ile imzalanmıştır.**

Belge Doğrulama Kodu : vU50LajJ177

Belge Doğrulama Adresi : <https://www.turkiye.gov.tr/esogu-ebys>

Adres : Meşelik Kampüsü 26040 Odunpazarı

Telefon : 0222 2393750 Faks: 0222 2291418

Bilgi için : Ceren KESKİNER

İnternet Adresi





T.C.  
ESKİŞEHİR OSMANGAZI ÜNİVERSİTESİ  
GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU  
BAŞKANLIĞI

**Prof.Dr.Merih ÖZGEN**  
(Başkan)  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Fizik Tedavi ve Rehabilitasyon AD

**Prof.Dr.Hava ÜSKÜDAR TEKE**  
(Başkan Yardımcısı)  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
İç Hastalıkları AD / Hematoloji BD

**Doç.Dr.Ferdi KÖŞGER**  
(Raportör)  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Ruh Sağlığı ve Hastalıkları AD

**Prof.Dr.Ömür ŞAYLIGİL**  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi Tıp Tarihi ve Etik AD

**Prof.Dr.Setenay DİNÇER ÖNER**  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi Biyoistatistik AD

**Prof.Dr.Batu Can YAMAN**  
Eskişehir Osmangazi Üniversitesi  
Diş Hekimliği Fakültesi  
Restoratif Diş Tedavisi AD

**Prof.Dr.Özlem ÖRSAL**  
Eskişehir Osmangazi Üniversitesi  
Sağlık Bilimleri Fakültesi  
Halk Sağlığı Hemşireliği AD

**Prof.Dr.Suzan ŞAYLISOY**  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi Radyoloji AD

**Doç.Dr.Göknur YORULMAZ**  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
İç Hastalıkları AD / Endokrinoloji  
ve Metabolizma Hastalıkları BD

**Doç.Dr.Muhammed Fatih ÖNSÜZ**  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi Halk Sağlığı AD

**Doç.Dr.Melih VELİPAŞAOĞLU**  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Kadın Hastalıkları ve Doğum AD

**Doç.Dr.Zeren BARIŞ**  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi  
Çocuk Sağlığı ve Hastalıkları AD /  
Çocuk Gastroenterolojisi BD

**Doç.Dr.Mustafa Değer BİLGEÇ**  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi Göz Hastalıkları AD

**Dr.Öğr.Üy.F.Nazlı DURMAZ ÇELİK**  
Eskişehir Osmangazi Üniversitesi  
Tıp Fakültesi Nöroloji AD

**Av. Önder CAN**  
Avukat

**Etik Kurul Sekreterliği**

Aysun SERTTAŞ

Ceren KESKİNER

Tel: 0 222 239 29 79 / 4690-91

**E-imzalıdır**

**Bu belge, güvenli elektronik imza ile imzalanmıştır.**

**Belge Do rulama Kodu : nbbK7pUL207**

**KARAR FORMU**

**Başvuru Tarihi:**  
26.08.2021

**Çalışmanın Başlığı:**

*“Konik Işınlı Bilgisayarlı Tomografi Görüntülerinin Yapay Zeka ile Değerlendirilmesi”*

**Çalışmacılar:**

Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı – Doç.Dr.İbrahim Şevki BAYRAKDAR, (Tez Danışmanı), Arş.Gör.Dt.Tuğba ARI (Tez Sahibi), Eskişehir Osmangazi Üniversitesi Fen Edebiyat Fakültesi Matematik–Bilgisayar Bölümü – Dr.Öğr.Üy.Özer ÇELİK

**Çalışmanın değerlendirildiği ilk toplantı tarihi:**

21.09.2021

**Sonuç:**

1. Kurum izinlerinin alınması araştırmacıların sorumluluğunda olup, ilgili kurumdan alınan izin yazılarının kurulumuza iletilmesi gerekmektedir.
2. Kişisel sağlık verileri kimliği belirli veya belirlenebilir gerçek kişiye ilişkin her türlü sağlık bilgisi olduğundan, kişisel sağlık verilerinin işlenmesi ile ilgili olarak ilgili mevzuat hükümleri dikkate alınmalı, verilerin yetkisiz kişilerin eline geçmesi önlenmelidir. Araştırmacıların kurulumuza taahhütnamelerle iletmış oldukları sorumlulukları yerine getirmeleri beklenmektedir.

**Karar Tarihi:**

21.09.2021

**Karar No:33**

Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı – Doç.Dr.İbrahim Şevki BAYRAKDAR’ın sorumluluğunda yürütülecek olan *“Konik Işınlı Bilgisayarlı Tomografi Görüntülerinin Yapay Zeka ile Değerlendirilmesi”* başlıklı araştırma/çalışma gereç, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve uygun bulunmuş olup, araştırmacının/çalışmanın gerçekleştirilmesinde etik ve bilimsel yönden sakınca bulunmadığına oy birliği ile karar verilmiştir.

Araştırmacılara başarılar dileriz.





**T.C.**  
**ESKİŞEHİR OSMANGAZI ÜNİVERSİTESİ**  
**GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU**  
**BAŞKANLIĞI**

**Çalışmanın Başlığı:** “Konik Işınlı Bilgisayarlı Tomografi Görüntülerinin Yapay Zeka ile Değerlendirilmesi”

**GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU**

|    | <b>Unvanı/Adı/Soyadı</b>                         | <b>Kurumu</b>  | <b>İmza</b>        |
|----|--|--|--------------------|
| 1  | Prof.Dr.Merih ÖZGEN<br>(Başkan)                  | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Fizik Tedavi ve Rehabilitasyon AD                                    | <i>e-imzalıdır</i> |
| 2  | Prof.Dr.Hava ÜSKÜDAR TEKE<br>(Başkan Yardımcısı) | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>İç Hastalıkları AD / Hematoloji BD                                   | <i>e-imzalıdır</i> |
| 3  | Doç.Dr.Ferdi KÖŞGER<br>(Raportör)                | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Ruh Sağlığı ve Hastalıkları AD                                       | <i>e-imzalıdır</i> |
| 4  | Prof.Dr.Ömür ŞAYLIGİL                            | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Tıp Tarihi ve Etik AD  | -                  |
| 5  | Prof.Dr.Setenay DİNÇER ÖNER                      | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Biyostatistik AD   | <i>e-imzalıdır</i> |
| 6  | Prof.Dr.Batu Can YAMAN                           | Eskişehir Osmangazi Üniversitesi<br>Diş Hekimliği Fakültesi Restoratif Diş Tedavisi AD                                 | <i>e-imzalıdır</i> |
| 7  | Prof.Dr.Özlem ÖRSAL                              | Eskişehir Osmangazi Üniversitesi<br>Sağlık Bilimleri Fakültesi Halk Sağlığı Hemşireliği AD                             | -                  |
| 8  | Prof.Dr.Suzan ŞAYLISOY                           | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Radyoloji AD   | <i>e-imzalıdır</i> |
| 9  | Doç.Dr.Göknur YORULMAZ                           | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>İç Hastalıkları AD /<br>Endokrinoloji ve Metabolizma Hastalıkları BD | <i>e-imzalıdır</i> |
| 10 | Doç.Dr.Muhammed Fatih ÖNSÜZ                      | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Halk Sağlığı AD  | <i>e-imzalıdır</i> |
| 11 | Doç.Dr.Melih VELİPAŞAOĞLU                        | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Kadın Hastalıkları ve Doğum AD                                       | -                  |
| 12 | Doç.Dr.Zeren BARIŞ                               | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Çocuk Sağlığı ve Hastalıkları AD /<br>Çocuk Gastroenterolojisi BD    | <i>e-imzalıdır</i> |
| 13 | Doç.Dr.Mustafa Değer BİLGEÇ                      | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Göz Hastalıkları AD  | <i>e-imzalıdır</i> |
| 14 | Dr.Öğr.Üy.F.Nazlı DURMAZ ÇELİK                   | Eskişehir Osmangazi Üniversitesi Tıp Fakültesi<br>Nöroloji AD  | -                  |
| 15 | Av.Önder CAN                                     | Hukuk  | -                  |

**E-imzalıdır**

**Bu belge, güvenli elektronik imza ile imzalanmıştır.**

**Belge Doğrulama Kodu : nbbK7pUL207**

