

T.C.
ESKİŐEHİR OSMANGAZI ÜNİVERSİTESİ
DİŐ HEKİMLİĐİ FAKÜLTESİ

DERİN ÖĐRENME YÖNTEMİNE DAYALI YAPAY ZEKÂ
ALGORİTMALARIYLA KONİK IŐINLI BİLGİSAYARLI
TOMOGRAFİ GÖRÜNTÜLERİNDE DİŐLERİN TESPİT
EDİLMESİ VE NUMARALANDIRILMASI

Hande SAĐLAM

AĐız, Diő ve Çene Radyolojisi Anabilim Dalı
Uzmanlık Tezi

Tez Danıőmanı
Doç. Dr. İbrahim Őevki BAYRAKDAR

ESKİŐEHİR

2021

T.C.
ESKİŐEHİR OSMANGAZI ÜNİVERSİTESİ
DİŐ HEKİMLİĐİ FAKÜLTESİ

DERİN ÖĐRENME YÖNTEMİNE DAYALI YAPAY ZEKÂ
ALGORİTMALARIYLA KONİK IŐINLI BİLGİSAYARLI
TOMOGRAFİ GÖRÜNTÜLERİNDE DİŐLERİN TESPİT
EDİLMESİ VE NUMARALANDIRILMASI

Hande SAĐLAM

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

2021

UZMANLIK TEZİ BEYANNAMESİ

Uzmanlık tezi olarak sunduđum “**DERİN ÖĐRENME YÖNTEMİNE DAYALI YAPAY ZEKÂ ALGORİTMALARIYLA KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE DİŞLERİN TESPİT EDİLMESİ VE NUMARALANDIRILMASI**” başlıklı arařtırmaı daniřmanım **Doç. Dr. İbrahim řevki BAYRAKDAR**’ın rehberlik ve sorumluluđunda tamamladıđım; çalışma 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 kaynakçanın eksiksiz olarak gösterildiđini, tezin yazım kılavuzu kurallarına uygun olarak hazırlandıđını ve belirtilen hususların aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim.

Hande SAĐLAM

İÇİNDEKİLER

İÇİNDEKİLER	I
TEŞEKKÜR	IV
ÖZET	V
ABSTRACT	VI
SİMGELER VE KISALTMALAR DİZİNİ	VII
TABLolar DİZİNİ	XII
1. GİRİŞ	1
2. GENEL BİLGİLER	2
2.1. Yapay Zekâ Nedir?	2
2.2. Makine Öğrenmesi	3
2.3. Yapay Sinir Ağları (Artificial Neural Network-ANN)	4
2.4. Yapay Sinir Ağlarının Özellikleri	6
2.5. Yapay Sinir Ağı Modelleri	7
2.5.1. Tek Katmanlı Algılayıcılar	8
2.5.2. Çok Katmanlı Algılayıcılar	8
2.5.3. İleri Beslemeli Yapay Sinir Ağları	9
2.5.4. Geri Beslemeli Yapay Sinir Ağları	9
2.6. Derin Öğrenme ve Derin Evrişimli Sinir Ağları	10
2.7. Evrişimli Sinir Ağı Katmanları	12
2.7.1. Giriş Katmanı (Input Layer)	12
2.7.2. Evrişim Katmanı (Convolution Layer)	12
2.7.3. Havuzlama Katmanı (Pooling Layer)	13
2.7.4. Tam Bağlı Katman (Fully Connected Layer)	13
2.7.5. Sınıflandırma Katmanı (Classification Layer)	14

2.8. Evrişimli Sinir Ağlarının Eğitilmesi.....	14
2.9. Aktivasyon Fonksiyonu	14
2.10. Transfer Öğrenme.....	15
2.10.1. AlexNet	15
2.10.2. VGGNet	16
2.10.3. GoogleNet	16
2.10.4. ResNet.....	17
2.11. Derin Öğrenme Mimarileri	17
2.11.1. Evrişimli Sinir Ağları (Convolutional Neural Network-CNN).....	17
2.11.2. Tekrarlayan Sinir Ağları (Recurrent Neural Network-RNN)	18
2.11.3. Uzun-Kısa Süreli Bellek Ağları (Long-Short Term Memory-LTSM)	18
2.11.4. Derin Oto-Kodlayıcılar (Deep Autoencoders)	19
2.11.5. Derin İnanç Ağları (Deep Belief Networks)	20
2.11.6. Derin Boltzmann Makinesi (Deep Boltzmann Machine)	20
2.12. Derin Öğrenmede Görüntü Segmentasyonu	21
2.12.1. Kodlayıcı-Kod Çözücü Modeller	21
2.12.2. U-Net ile Görüntü Segmentasyonu.....	22
2.13. Derin Öğrenme Kütüphaneleri.....	22
2.14. Dış Hekimliğinde Yapay Zekâ ve Kullanım Alanları	23
2.14.1. Ağız, Diş ve Çene Radyolojisi Alanında Yapay Zekâ.....	23
2.14.2. Ortodonti Alanında Yapay Zekâ	24
2.14.3. Ağız, Diş ve Çene Cerrahisi Alanında Yapay Zekâ	25
2.14.4. Restoratif Diş Hekimliği Alanında Yapay Zekâ	26
2.14.5. Periodontoloji Alanında Yapay Zekâ	27
2.14.6. Ağız Kanserleri ve Yapay Zekâ	29

2.14.7. Adli Diş Hekimliği Alanında Yapay Zekâ.....	30
2.15. Konik Işınlı Bilgisayarlı Tomografi (KIBT).....	30
3. MATERYAL VE METOT.....	32
3.1. Hasta Seçimi.....	32
3.2. Radyografik Veri Setinin Elde Edilmesi	32
3.3. Görüntü Değerlendirmesi.....	33
3.4. Derin Öğrenme Mimarisi.....	35
3.5. Model Geliştirilmesi.....	36
3.6. Eğitim Aşaması	36
3.7. İstatiksel Analiz.....	49
3.7.1. Karmaşıklık Matris Hesaplama Prosedürü	50
3.8. Performans Değerlendirmesi.....	50
3.9. Alıcı İşlem Karakteristiği (AİK-ROC)	52
4. BULGULAR.....	53
4.1. ROC (Receiver Operating Characteristic Curve) Eğrisi Grafikleri ve AUC (Area Under Curve).....	55
4.2. Precision (Kesinlik) -Recall (Hassasiyet) Eğrisi (PR Eğrisi).....	59
5. TARTIŞMA.....	63
6. SONUÇ VE ÖNERİLER.....	74
KAYNAKLAR	75
EKLER.....	99
EK-1. ÖZGEÇMİŞ.....	99
EK-2. ETİK KURUL ONAYI.....	101

TEŞEKKÜR

Uzmanlık eğitimim boyunca bana destek olup, engin mesleki bilgi ve deneyimlerini benimle cömertçe paylaşan, bu süreçte beni motive eden değerli hocam ve tez danışmanım Doç. Dr. İbrahim Şevki BAYRAKDAR'a,

Uzmanlık eğitimim boyunca bilgi ve tecrübelerinden yararlandığım, emeğini ve ilgisini benden esirgemeyip eğitimimde önemli katkısı olan değerli hocalarım Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyoloji Anabilim Dalı öğretim üyeleri Doç. Dr. Esra YEŞİLOVA'ya ve Doç. Dr. Elif BİLGİR'e,

Çalışmamızın yapay zekâ uygulamalarıyla analizini yapan ve sonuçlarını elde eden Dr. Öğr. Üyesi Özer ÇELİK'e ve ekibine,

Her zaman desteklerini hissettiğim birlikte çalıştığım değerli asistan arkadaşlarım Tuğba ARI'ya, Hasan ÖKSÜZOĞLU'na ve Ağız, Diş ve Çene Radyolojisi kliniği çalışanlarına,

Her zaman yanımda olan ve en zor günlerde dahi desteklerini esirgemeyen, ellerinden geleni yapan anneme, babama ve kardeşime,

Üniversite hayatımın başından beri anlayışı ve sevgisiyle hep yanımda olan hayat arkadaşım Orhan KAZAN'a,

Sonsuz teşekkürlerimi sunarım.

Hande SAĞLAM

ÖZET

Derin Öğrenme Yöntemine Dayalı Yapay Zekâ Algoritmalarıyla Konik Işınlı Bilgisayarlı Tomografi Görüntülerinde Dişlerin Tespit Edilmesi ve Numaralandırılması

Amaç: Son yıllarda yaşam kalitemiz üzerinde önemli değişikliklere sebep olan gelişmelerden biri AI'dır. Özellikle radyoloji alanında birçok gelişmeye katkısı olan AI, diş hekimliğinde de popülerlik kazanmaya başlamıştır. Bu çalışmada, DCNN kullanarak KIBT görüntülerinde dişleri tespit edip, numaralandırmak için otomatik bir yöntem geliştirmeyi amaçladık.

Materyal ve Metot: Veri seti 103 adet KIBT DICOM görüntüsünden oluşan çalışmamızda, transfer öğrenme teknikleriyle uyguladığımız Inception ResNet v2, Inception v2 ve ResNet-101 mimarilerinin diş tespit ve numaralandırmadaki başarıları karşılaştırılmıştır. Görüntüler üzerinde dişlerin etiketlenmesi CranioCatch etiketleme yazılımı (CranioCatch, Eskişehir, Türkiye) kullanılarak yapılmıştır. Karmaşıklık matris yöntemi kullanılarak her bir modele ait başarı metrikleri hesaplanmıştır.

Bulgular: Diş tespit ve numaralandırma için; Inception v2 mimarisi için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.9440, 0.9325 ve 0.9382 şeklindedir. Inception ResNet v2 mimarisi için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.9438, 0.9567 ve 0.9502 şeklindedir. ResNet-101 mimarisi için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.9450, 0.9380 ve 0.9415 şeklindedir. Inception v2, Inception ResNet v2 ve ResNet-101 için AUC değerleri ise sırasıyla; 0.9389, 0.9485 ve 0.9493 olarak elde edilmiştir. En yüksek AUC değerine sahip mimari ResNet-101 olmuştur.

Sonuç: Çalışmamız ilerleyen zamanlarda yapılacak olan derin öğrenme tabanlı KIBT raporlama sistemlerinin gelişimi açısından çok önemlidir. Bu sistemlerin klinik rutininde hekimlere zaman kazandırarak bir karar destek mekanizması rolü göreceğini düşünmekteyiz.

Anahtar Kelimeler; Derin öğrenme, Diş tespiti, Konik ışınlı bilgisayarlı tomografi, Yapay zekâ

ABSTRACT

Detection and Numbering of Teeth in Cone-Beam Computed Tomography Images with Artificial Intelligence Algorithms Based on Deep Learning Method

Aim: One of the developments that have caused significant changes in our quality of life in recent years is AI. AI, which has contributed to many developments especially in the field of radiology, has also started to gain popularity in dentistry. In this study, we aimed to develop an automated method to detect and numbering teeth in CBCT images using DCNN.

Material and Method: In our study, whose data set consists of 103 CBCT DICOM images, the success of Inception ResNet v2, Inception v2, and ResNet-101 architectures, which we applied with transfer learning techniques, in tooth detection and numbering were compared. Labeling of teeth on images was done using CranioCatch labeling software (CranioCatch, Eskisehir, Turkey). Success metrics for each model were calculated using the confusion matrix method.

Results: For tooth detection and numbering; The sensitivity, precision, and F1 score values for the Inception v2 architecture are 0.9440, 0.9325, and 0.9382, respectively. The sensitivity, precision, and F1 score values for the Inception ResNet v2 architecture are 0.9438, 0.9567, and 0.9502, respectively. The sensitivity, precision, and F1 score values for the ResNet-101 architecture are 0.9450, 0.9380, and 0.9415, respectively. AUC values for Inception v2, Inception ResNet v2 and ResNet-101 are respectively; 0.9389, 0.9485 and 0.9493 were obtained. The architecture with the highest AUC value was ResNet-101.

Conclusion: Our study is very important for the development of deep learning-based CBCT reporting systems to be made in the future. We think that these systems will play a role as a decision support mechanism by saving time for physicians in their clinical routine.

Keywords: Artificial intelligence, Cone-beam computerized tomography, Deep learning, Tooth detection

SİMGELER VE KISALTMALAR DİZİNİ

%	: Yüzde
2B	: İki Boyutlu
3B	: Üç Boyutlu
AI	: Yapay Zekâ (Artificial Intelligence)
ANN	: Yapay Sinir Ağları (Artificial Neural Networks)
Ark.	: Arkadaşları
AUC	: Area Under Curve
CNN	: Evrişimli Sinir Ağları (Convolutional Neural Networks)
BT	: Bilgisayarlı Tomografi
DCNN	: Derin Evrişimli Sinir Ağları (Deep Convolutional Neural Networks)
DICOM	: Digital Imaging and Communications in Medicine
DL	: Derin Öğrenme (Deep Learning)
FCN	: Tamamen Bağlı Ağ (Fully Connected Network)
FDI	: Federation Dentaire Internationale
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
IoU	: Intersection Over Union
KIBT	: Konik Işınli Bilgisayarlı Tomografi
Kv	: Kilovolt
LTSM	: Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory)
mA	: Miliamper

MIT	: Massachusetts Institute of Technology
ML	: Makine Öğrenmesi (Machine Learning)
MÖ	: Milattan Önce
PDS	: Pederson Zorluk Skoru (Pederson Difficulty Score)
PR	: Kesinlik-Hassasiyet Eğrisi (Precision-Recall Curve)
R-CNN	: Bölgeye Dayalı Evrişimli Sinir Ağları (Region-Based Convolutional Network)
RNN	: Tekrarlayan Sinir Ağları (Recurrent Neural Network-RNN)
ROC	: Alıcı İşlem Karakteristiği (Receiver Operating Characteristic)
RPN	: Bölge Öneri Ağı (Region Proposal Network)
TME	: Temporomandibular Eklem
TN	: Doğru Negatif (True Negative)
TP	: Doğru pozitif (True pozitif)

ŞEKİLLER DİZİNİ

<u>Şekil No</u>	<u>Sayfa No</u>
Şekil 2.1. Turing testi	3
Şekil 2.2. Yapay zekâyı oluşturan temel kavramlar	4
Şekil 2.3. Biyolojik sinir hücresi ve yapay sinir ağı	5
Şekil 2.4. Yapay sinir ağı nöron modeli	6
Şekil 2.5. Tek katmanlı algılayıcı modeli	8
Şekil 2.6. Çok katmanlı algılayıcı model	8
Şekil 2.7. İleri beslemeli ağ yapısı	9
Şekil 2.8. Geri beslemeli ağ yapısı	10
Şekil 2.9. a) Makine öğrenmesi, b) Derin öğrenme	11
Şekil 2.10. DCNN mimarisi	12
Şekil 2.11. Evrişim işlemi	13
Şekil 2.12. Havuzlama örneği	13
Şekil 2.13. AlexNet mimarisi	15
Şekil 2.14. VGG-16 mimarisi	16
Şekil 2.15. GoogleNet mimarisi	16
Şekil 2.16. ResNet mimarisi	17
Şekil 2.17. RNN modeli	18
Şekil 2.18. LSTM ağ yapısı	19
Şekil 2.19. Derin oto-kodlayıcı ağ modeli	19
Şekil 2.20. Derin inanç ağları modeli	20
Şekil 2.21. Derin Boltzmann Makinesi modeli	20
Şekil 3.1. Üst çenede dişlerin poligonal tarzda etiketlenmesi	34

Şekil 3.2. Alt çenede dişlerin poligonal tarzda etiketlenmesi	34
Şekil 3.3. Poligonal tarzda etiketlenen 46 nolu dişin görüntüsü.....	35
Şekil 3.4. Inception ResNet v2 mimarisi ile gerçekleştirilen diş tespit modelinin gelişim aşamalarının diyagramı	38
Şekil 3.5. Inception v2 mimarisi ile gerçekleştirilen diş tespit modelinin gelişim aşamalarının diyagramı.....	39
Şekil 3.6. ResNet-101 mimarisi ile gerçekleştirilen diş tespit modelinin gelişim aşamalarının diyagramı.....	40
Şekil 3.7. AI algoritmalarının diş tespiti için oluşturduğu tahmini görüntüler (TP, gerçek pozitif).....	41
Şekil 3.8. AI algoritmalarının diş tespiti için oluşturduğu tahmini görüntüler (TP, gerçek pozitif).....	42
Şekil 3.9. AI algoritmalarının diş tespiti için oluşturduğu tahmini görüntüler (a: FN (yanlış negatif), b: FP (yanlış pozitif)).....	43
Şekil 3.10. Inception ResNet v2 mimarisi ile gerçekleştirilen diş tespit ve numaralandırma modelinin gelişim aşamalarının diyagramı	44
Şekil 3.11. Inception v2 mimarisi ile gerçekleştirilen diş tespit ve numaralandırma modelinin gelişim aşamalarının diyagramı	45
Şekil 3.12. AI algoritmalarının alt ve üst çenede dişlerin tespitinde ve numaralandırmada oluşturduğu tahmini görüntüler (TP, gerçek pozitif).....	47
Şekil 3.13. AI algoritmalarının diş tespitinde ve numaralandırmada oluşturduğu tahmini görüntüler (TP, gerçek pozitif).....	48
Şekil 3.14. AI algoritmalarının diş tespit ve numaralandırmada oluşturduğu tahmini görüntüler (a: FN (yanlış negatif), b: FP (yanlış pozitif))..	49

Şekil 4.1. TPR ve FPR değerlerinin formülleri.....	55
Şekil 4.2. Inception ResNet v2 mimarisine ait dış tespit için ROC eğrisi.....	55
Şekil 4.3. Inception v2 mimarisine ait dış tespit için ROC eğrisi.....	56
Şekil 4.4. ResNet-101 mimarisine ait dış tespit için ROC eğrisi.....	56
Şekil 4.5. Inception ResNet v2 mimarisine ait dış tespit ve numaralandırmadaki ROC eğrisi.....	57
Şekil 4.6. Inception v2 mimarisine ait dış tespit ve numaralandırmadaki ROC eğrisi.....	58
Şekil 4.7. ResNet-101 mimarisine ait dış tespit ve numaralandırmadaki ROC eğrisi.....	58
Şekil 4.8. Inception ResNet v2 mimarisine ait dış tespiti için Precision-Recall eğrisi.....	60
Şekil 4.9. Inception v2 mimarisine ait dış tespiti için Precision-Recall eğrisi ..	60
Şekil 4.10. ResNet-101 mimarisine ait dış tespiti için Precision-Recall eğrisi..	61
Şekil 4.11. Inception ResNet v2 mimarisine ait dış tespit ve numaralandırma için Precision-Recall eğrisi ..	61
Şekil 4.12. Inception v2 mimarisine ait dış tespit ve numaralandırma için Precision-Recall eğrisi.....	62
Şekil 4.13. ResNet-101 mimarisine ait dış tespit ve numaralandırma için Precision-Recall eğrisi.....	62

TABLULAR DİZİNİ

<u>Tablo No</u>	<u>Sayfa No</u>
Tablo 2.1. Biyolojik sinir hücresi ve yapay sinir ağı terminolojisi	5
Tablo 3.1. Veri seti sınıflandırması	37
Tablo 3.2. Modelin başarısını değerlendirmek için kullanılan ön hesaplamaların açıklaması.....	51
Tablo 3.3. TP, FP ve FN sayısal değerleri ile hassasiyet, kesinlik ve F1 skoru hesaplama formülleri.....	51
Tablo 4.1. Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespiti için TP, FP ve FN değerleri.....	54
Tablo 4.2. Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespiti için duyarlılık, kesinlik ve F1 skoru performans ölçüm değerleri.....	54
Tablo 4.3. Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespit ve numaralandırma için TP, FP ve FN değerleri.....	54
Tablo 4.4. Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespit ve numaralandırma için duyarlılık, kesinlik ve F1 skoru performans ölçüm değerleri.....	54
Tablo 4.5. Çalışmada eğitilen modellerin dış tespiti için AUC değerleri.....	57
Tablo 4.6. Çalışmada eğitilen modellerin dış tespit ve numaralandırma için AUC değerleri.....	59

1. GİRİŞ

Yaşadığımız çağ içinde yaşam kalitemiz üzerinde önemli değişikliklere sebep olan teknolojik gelişmeler olmaktadır. Bu değişikliklere sebep olan en önemli gelişmelerden biri de yapay zekâdır (Artificial Intelligence-AI). AI matematiksel hesaplama gücü, veri depolama kapasitesi ve farklı işlemleri gerçekleştirebilmesi sayesinde tıpta ve radyolojide popülerlik kazanmıştır.¹

AI'nin teşhis sürecini hızlandırarak hastalıkların prognozunu etkileyeceği düşünülmektedir.² AI, insan zekâsını simüle eden bilgisayar ağlarını (sinir ağları) içerir. AI'nın radyolojiye dâhil edilmesi ile tanısal görüntüleme ile ilgili bulguları tespit etmek ve tespit edilen görüntüleri daha küçük verilere ayırmak kolaylaşacaktır. AI radyolog eksikliği olan popülasyonlarda ve tarama programlarında büyük bir etkiye sahip olacaktır.² Radyoloji pratiğinde önemli değişikliklere neden olacağı öngörülmektedir.³ Radyologların mesleğin klinik ve pratik anlamda geleceği için, AI'nın ne anlama geldiğini, hangi konular üzerinde değişiklik ve kolaylık sağlayacağını, mesleğe nasıl katkıda bulunacağını bilmeleri gerekmektedir. AI bir insandan çok daha hızlı ve güvenilir veriler sunabilir.⁴

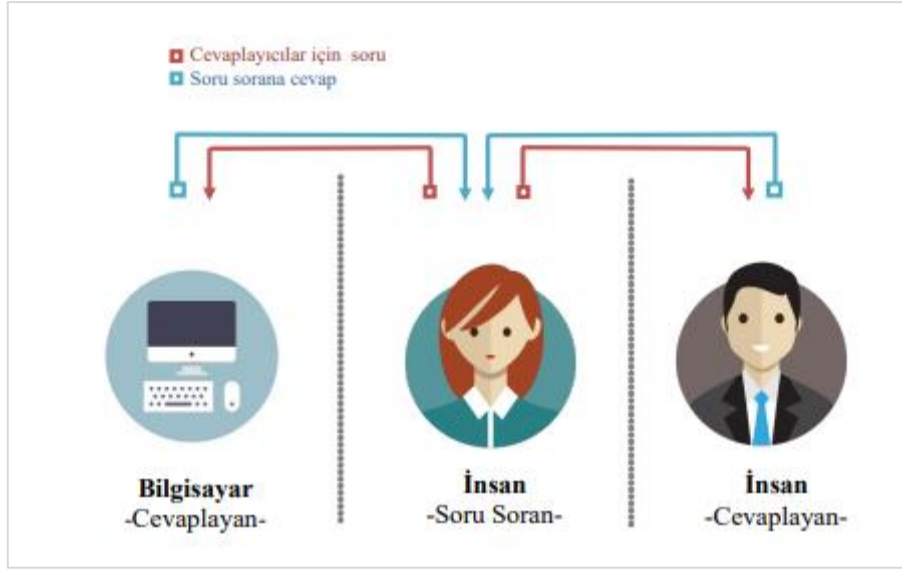
Bu çalışmada, derin evrişimli sinir ağlarından (Deep Convolutional Neural Networks -DCNN) ve algoritmik sezgiden oluşan otomatik bir sistem önermekteyiz. Amacımız, otomatik dental çizelge sisteminin bir bileşeni olarak, DCNN kullanarak konik ışınli bilgisayarlı tomografi (KIBT) görüntülerinde dişlerin tespitini ve numaralandırmasını gerçekleştirmektir.

2. GENEL BİLGİLER

2.1. Yapay Zekâ Nedir?

“Tarihte üç büyük olay vardır. Bunlardan ilki kâinatın oluşumudur. İkincisi yaşamın başlangıcının oluşmasıdır. Üçüncüsü de yapay zekânın ortaya çıkışıdır.” Bu sözler Massachusetts Institute of Technology (MIT) Bilgisayar Bilimleri laboratuvar yöneticilerinden Edward Fredkin’e aittir.⁵ İnsanoğlu yüzyıllardan beri nesnelere harekete geçirebilme, nesnelere insan gibi düşünebilme yetisi kazandırabilme düşüncesindedir. MÖ (Milattan Önce) 384 - 322 yılları arasında yaşayan Aristoteles’e ait belgelerde de bu düşüncelere ait bulgular tespit edilmiştir.^{6,7}

AI’nın esas olarak ortaya çıkışı bilgisayar bilim dalı uzmanı Alan Turing’in makine zekâsı testini gerçekleştirmesiyle olmuştur. “Makineler düşünebilir mi?” sorusu ile bir makinenin insan gibi düşünebilmesi ve zeki olabilmesi fikrini ortaya atan ilk kişidir. Turing testi adı verilen yaptığı çalışmada, eğer bir insan etkileşim sırasında insan-bilgisayar arasındaki farkı ayırt edemiyorsa, o zaman bilgisayarı insan kadar akıllı kabul etmek gerektiği yolundaki varsayımı ortaya atmıştır.^{6, 8} Şekil 2.1’de Turing testi gösterilmiştir.



Şekil 2.1. Turing testi⁹

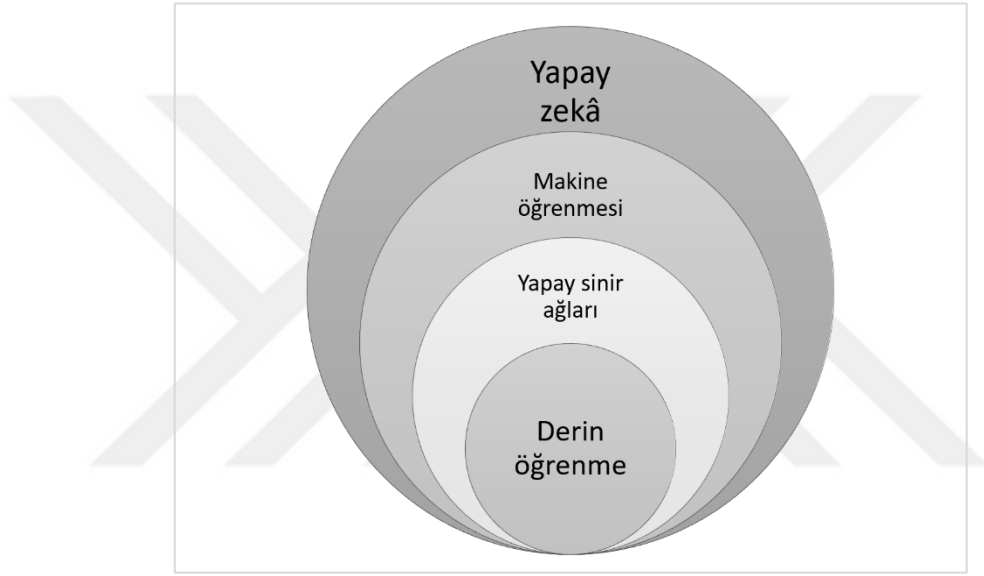
AI'nın ayrı bir araştırma alanı olarak gündeme gelmesi ve “yapay zekâ” teriminin ortaya çıkması ise 1956'da Hannover, New Hampshire, Dartmouth College'da yapılan bir konferansta gerçekleşmiştir. Bu kavramın yaratıcısı olan McCarthy, AI'yı, “İnsan benzeri zeki makineler özellikle de zeki bilgisayar programları yapma bilimi ve mühendisliği” olarak tanımlamıştır.¹⁰ Bu konferans önemli bir dönüm noktası olmuştur. Richard Bellman adlı bir matematikçi 1970'lerde, AI'yı; öğrenme, karar verme, problem çözme ve insan gibi düşünce üretebilme etkinliklerinin otomatik olarak yapılabilmesi olarak tanımladı.¹¹ Günümüzde AI insan bilişsel becerilerini taklit edebilen herhangi bir makineyi veya teknolojiyi ifade etmektedir.¹²

2.2. Makine Öğrenmesi

AI teknolojisindeki amaç, yüklenen veriler aracılığıyla makinelerin problemleri çözme yeteneği kazanması olarak ifade edilmektedir.¹² Bu teknolojiyi anlayabilmek için “Makine Öğrenmesi (Machine Learning, ML)”, “Yapay Sinir Ağları (Artificial Neural

Network, ANN)” ve “Derin Öğrenme (Deep Learning, DL) ” terimlerini bilmek gerekmektedir (Şekil 2.2). ML, AI algoritmalarının en önemli yapıtaşıdır.

Yüklenen veriler aracılığıyla makinelerin, insan müdahalesi olmadan, öğrendiği kalıplar aracılığıyla problemi çözmesidir.¹² ML algoritmaları ne kadar fazla veriye maruz kalırsa o kadar fazla gelişir ve daha iyi değerlendirme yaparak özel cevaplar vermeyi öğrenir.¹³



Şekil 2.2. Yapay zekâyı oluşturan temel kavramlar¹²


ML, AI'nın önemli bir alt alanıdır, verilerin istatistiksel kalıplarını ve yapılarını algoritmalar sayesinde öğrenir. ML insan beyninin art arda farklı girdiler (veriler) işleyerek, görüntüleri tespit etmesini, öğrenmesini, kendi kendini düzeltmesini, sınıflandırmasını, alt sınıflama yapmasını temel alan bir tekniktir.²

2.3. Yapay Sinir Ağları (Artificial Neural Network-ANN)

En popüler ML modeli ANN'dir. ANN insan beynini oluşturan nöronları taklit edilerek oluşturulan bir algoritmadır. ANN biyolojik benzerlerini taklit eder. Verileri

birbirine katmanlar halinde düzenlenmiş bir düğüm ağından geçirirler.¹⁴ Nörolog Donald Hebb 1949 yılında sinir ağı teorisini ortaya atmıştır ve bu alanda çalışmalar yapmıştır. Donald Hebb, ANN'nin biyolojik sinir ağlarını taklit eden bilgisayar programları olduğunu belirtmiştir.^{15, 16}

Şekil 2.3.'te biyolojik bir sinir hücresi ve ANN'nin şematik olarak gösterimleri eklenmiştir. Tablo 2.1.'de ise biyolojik sinir hücresi ve ANN'nin terimsel karşılaştırması verilmiştir.



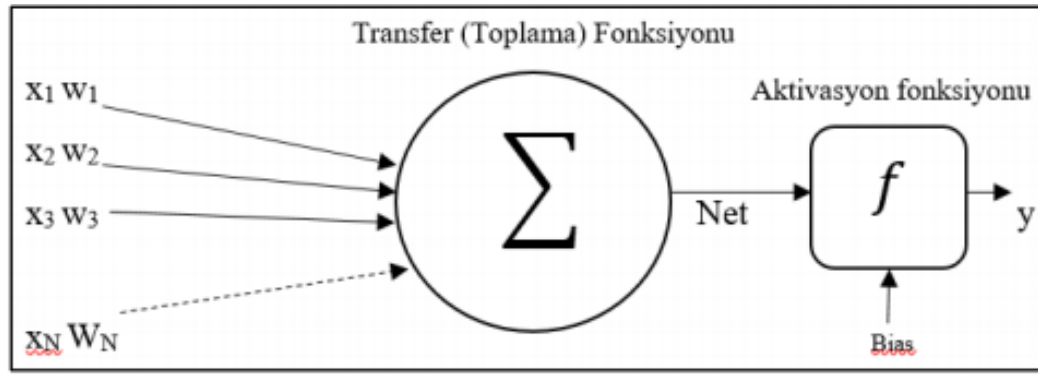
Şekil 2.3. Biyolojik sinir hücresi ve yapay sinir ağı¹⁷

Tablo 2.1. Biyolojik sinir hücresi ve yapay sinir ağı terminolojisi⁷

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Yapay bir nöron hücresine n tane veri girişi olmaktadır ($x_1, x_2, x_3, \dots, x_N$). Bu veri girdilerine karşılık ağırlık değerleri ($w_1, w_2, w_3, \dots, w_N$) ağ üzerindeki etki değerleridir. Tüm girilen veriler ağırlık değerleri ile çarpılarak transfer fonksiyonuyla birleştirilip aktivasyon fonksiyonundan geçmektedir (Şekil 2.4.).¹⁸

Aktivasyon fonksiyonundan elde edilen değer çıkış değeri olarak ifade edilmektedir. Bir yapay sinir hücresinin birden çok girdisi olmasına rağmen tek bir çıktı değeri bulunmaktadır.¹⁹



Şekil 2.4. Yapay sinir ağı nöron modeli¹⁸

ANN insan beyni nöron ve sinapslarının mimarisini öğrenerek hesaplama birimlerini modeller.²⁰ Düğümlerden ve ağırlıklardan (sinapslar) oluşan ANN'lerin hesaplama gücü, bu bağlantıların ağırlıkların güncellenmesini sağlayacak olan eğitim veri setlerinin kalitesi ve miktarına bağlıdır.^{21, 22} Ağırlıklar veriler arasında en uygun olanı değeri bulmaya çalışır ve bu sayede ANN'nin eğitimi gerçekleşmiş olur.⁷

2.4. Yapay Sinir Ağlarının Özellikleri

ANN birçok özelliğe sahiptir:⁷

- Doğrusal olmama

- Paralel çalışma
- Öğrenme
- Genelleme
- Hata toleransı ve esneklik
- Eksik verilerle çalışma
- Çok sayıda değişken ve parametre kullanma
- Uyarlanabilirlik

ANN sıklıkla tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme gibi işlemlerde kullanılmaktadır.²³

Tahmin: ANN'nin girdi değerlerinden çıktıları tahmin etmesi olarak ifade edilmektedir.

Veri filtreleme: Toplanan veriler arasında en işe yarayacak olan verileri kullanması olarak ifade edilmektedir.

Veri yorumlama: Eğitilen ağ girdilerini analiz ederek bir durum karşısından yeni yorumlamalar yapabilmesidir.


Veri ilişkilendirme: Daha öğrendiği konuları birbiriyle ilişkilendirmesi ve eksik olan bilgileri tamamlaması olarak ifade edilmektedir.⁷

2.5. Yapay Sinir Ağı Modelleri

ANN modelleri tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli ANN ve geri beslemeli ANN olarak 4 grup altında incelenmektedir.⁷

2.5.1. Tek Katmanlı Algılayıcılar


Tek katmanlı algılayıcılar sadece girdi ve çıktıdan oluşmaktadır, çıktı fonksiyonu doğrusaldır (Şekil 2.5).⁷



Şekil 2.5. Tek katmanlı algılayıcı modeli¹⁹

2.5.2. Çok Katmanlı Algılayıcılar

Çok katmanlı algılayıcılar; yapısal olarak doğrusal olmayan aktivasyon fonksiyonu olan birçok nöronun birbirine bağlı olduğu yapılar olarak ifade edilmektedir (Şekil 2.6.).⁷




Şekil 2.6. Çok katmanlı algılayıcı modeli²⁴

2.5.3. İleri Beslemeli Yapay Sinir Ağları

ANN üç farklı katmandan oluşmaktadır; girdi, gizli (ara) ve çıktı katmanları. Girdi ve çıktı katmanı tek iken, gizli katman sayısı farklılık göstermektedir. Girdi katmanı verinin ağa tanıtımının yapıldığı katmandır ve bu katmandan sonra veri ağırlıkları ile çarpılarak gizli katmana aktarılmaktadır. Gizli katman ANN'nin temel yapısını oluşturmakla birlikte, bu katmandaki veriler de ağırlıklar ile çarpılarak çıktı katmanına aktarılır ve bu katman bir çıkış üretir.²⁵⁻²⁷

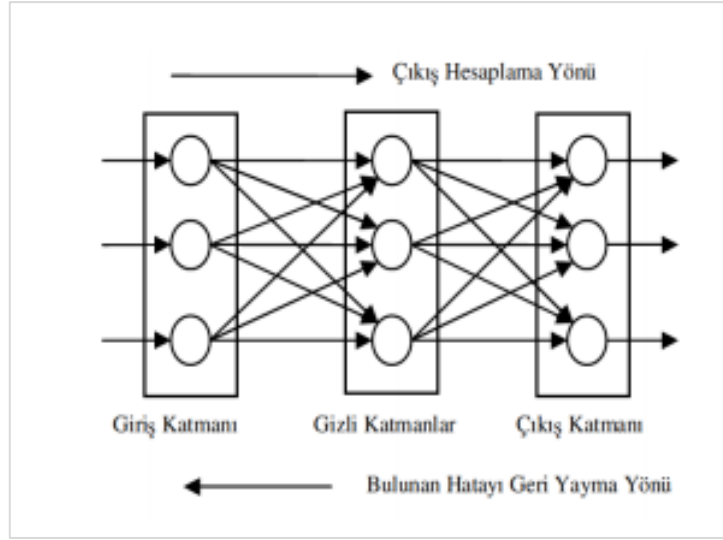
İleri beslemeli ANN'de veriler girdi katmanından, gizli katmana iletilir. Sonrasında çıktı katmanına doğru düzenli katmanlar şeklinde ilerler ve dış ortama aktarılır. Bir katmandan sonra sadece kendinden sonraki katmanlar için bağ bulunmaktadır. Geri besleme aşaması yoktur (Şekil 2.7.). Uygulamalarda genelde kullanılan ANN modeli ileri beslemeli ağ modelidir.^{7, 26, 28}



Şekil 2.7. İleri beslemeli ağ yapısı⁷

2.5.4. Geri Beslemeli Yapay Sinir Ağları

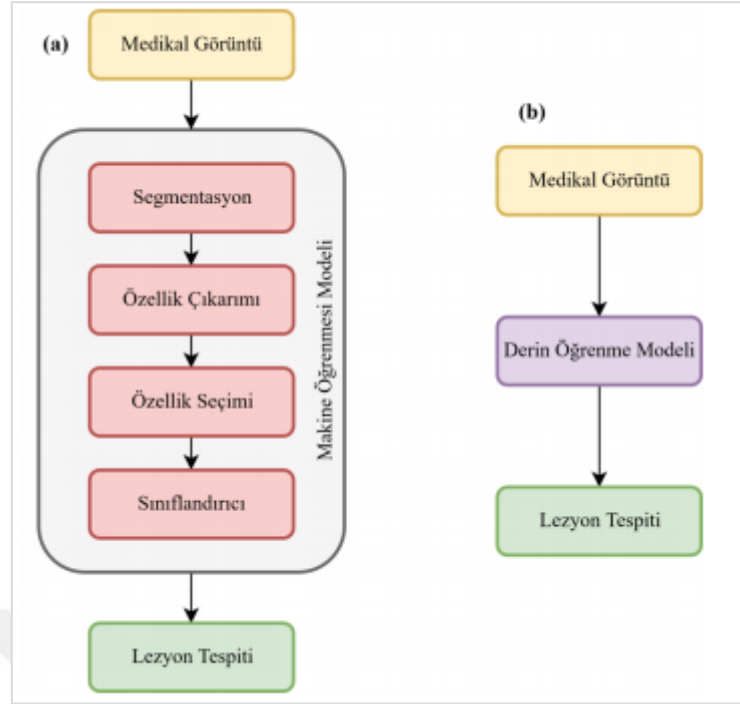
Geri beslemeli ağlar ileri beslemeli ağlar gibi tek yönlü değildir. Hem ileriye hem geriye veri akışı sağlayabilmektedirler (Şekil 2.8). Veri akışı aynı veya farklı katmanlar arasında olabilmektedir. Doğrusal olmayan dinamik bir ağ modelidir.^{7, 28}



Şekil 2.8. Geri beslemeli ağ yapısı⁷

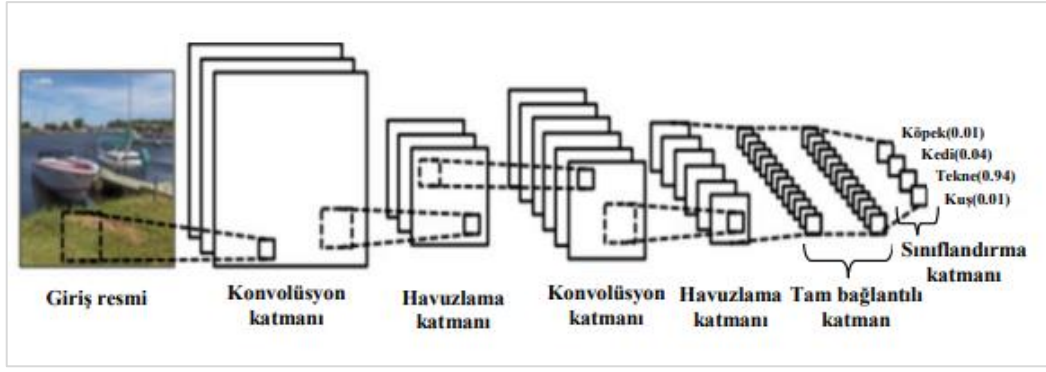
2.6. Derin Öğrenme ve Derin Evrişimli Sinir Ağları

DL, ML'nin bir alt bileşenidir. Görüntülerin yorumlanmasının yapıldığı AI sistemlerinin çoğunun alt yapısını oluşturmaktadır.²⁹ ML algoritmalarında mevcut görüntü bir ön-işlem sürecinden geçirilir ve sonrasında kontrast, ovallık, boyut gibi özellikleri tanımlar. Belirli sınıflarla eğitilen ML modelleri sonrasında verilecek olan yeni problem karşısında verilen özelliklerin olup olmamasına bağlı kalarak bir çıkarım yapar (Örneğin bir görüntüde kanser varlığını ya da yokluğunu tespit etmesi gibi). Piksel tabanlı bir sınıflama yapan DL modelleri ise, bu ön-işleme sürecini gerçekleştirmeden sınıflandırmayı başarabilirler. Görüntüdeki belli özellikleri tespit ederek sınıflama yapan ML modellerinin aksine, yapılan eğitim sonucunda, sadece ham veriyi işleyerek çıkarım yapabilme özelliğine sahiptir.(Şekil 2.9).³⁰



Şekil 2.9. a) Makine öğrenmesi, b) Derin öğrenme³¹

DL yöntemindeki algoritmalar denetimli (sınıflandırma) veya denetimsiz (desen analizi) şekilde olabilmektedir.³² DL yöntemi çok katmanlı ANN kavramına dayanmaktadır. Bu yöntemde derin sinir ağları kullanılır, çok katmanlı olan bu sistem daha karmaşık problemleri çözebilecek yetenektedir.³³ DL AI'nın en yeni sürümüdür, temel olarak girdiler ve çıktılar arasındaki ANN, katman sayısı bakımından önceki ANN'lerden farklıdır.^{20,34} Bu katmanlar sayesinde girdilerden veri toplar. Öğrendiği yeni özellikler sayesinde adım adım değişebilen bir çıktı sağlar.²⁹ Bu çok sayıda katman içeren ağ yapılarına derin DCNN denmektedir (Şekil 2.10.). Katmanlarından birçok özelliği çıkarabilen bu yapılar, esas olarak daha büyük ve karmaşık görüntüleri işlemek için kullanılmaktadır.²² Farklı görevleri yerine getirecek olan bu katmanlar medikal görüntülerde; hastalık teşhisi, sınıflandırma, nesne tanımlama gibi işlemleri gerçekleştirebilirler.¹⁸



Şekil 2.10. DCNN mimarisi³⁵


2.7. Evrişimli Sinir Ağı Katmanları

2.7.1. Giriş Katmanı (Input Layer)

DCNN'ye ham olarak verilen giriş görüntüsünü ifade etmektedir.¹⁸

2.7.2. Evrişim Katmanı (Convolution Layer)

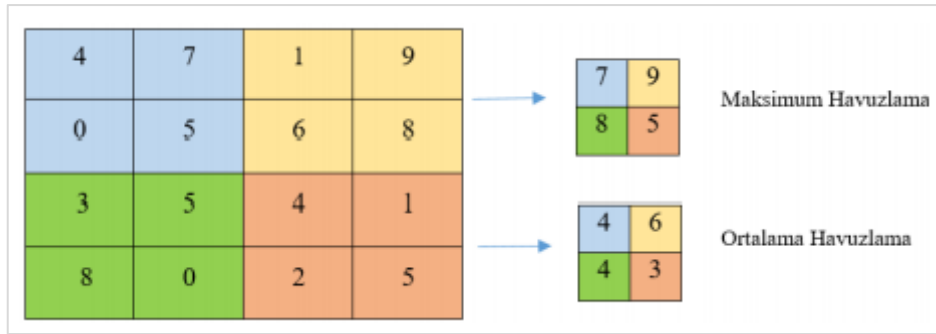
Evrişim katmanı giriş görüntüsünden filtreler (çekirdekler) aracılığıyla özellik (öznitelik) çıkarımlarının yapıldığı katmanı tanımlamaktadır. İlk evrişim katmanında kenar bilgileri gibi temel özellikler belirlenirken, diğer katmanlara doğru üst düzey ve karmaşık özelliklerin tespiti gerçekleştirilir.³⁶ Şekil 2.11'de evrişim işlemi gösterilmiştir.



Şekil 2.11. Evrişim işlemi¹⁸

2.7.3. Havuzlama Katmanı (Pooling Layer)

Havuzlama katmanı evrişim katmanında elde edilen fazla sayıdaki parametrenin özeltendiği katmandır. Evrişim katmanındaki gibi çeşitli boyutlardaki filtreler aracılığıyla, komşu piksellerin ortalama ya da maksimum değerleri hesaplanarak tek bir değer olarak ifade edilmektedir.^{18, 37} Şekil 2.12’de Havuzlama örneği gösterilmiştir.



Şekil 2.12. Havuzlama örneği¹⁸

2.7.4. Tam Bağlı Katman (Fully Connected Layer)

Genellikle havuzlama katmanından sonra gelen bu katman, kendinden önceki tüm katmanın tüm alanlarına bağlıdır bu nedenle tam bağlantılı katman olarak adlandırılmaktadır.³⁸

2.7.5. Sınıflandırma Katmanı (Classification Layer)

Tam bağı katmandan sonra gelen bu katmanda sınıflandırma işlemi gerçekleştirilmektedir. Çıkış değeri sınıflandırılması yapılacak olan grup sayısına eşittir.³⁸

2.8. Evrişimli Sinir Ağlarının Eğitilmesi

DCNN eğitimi ilk olarak modelin oluşturulmasıyla başlar. Modeldeki evrişim katmanı, havuzlama katmanı, tam bağlantılı katman ve sınıflandırma katman sayısı belirlenir. Daha sonrasında bu katmanların sıralaması oluşturulur. Bir sonraki aşamada değişkenler tanımlanır (filtre boyutları ve sayısı, adım kayma miktarı). Elde edilen modele eğitim setinden bir görüntü verilir. Daha sonra ileri besleme ile her katmanda her bir filtrenin ağırlıkları ile görüntüdeki piksel değerleri çarpılarak bir sonraki katmana aktarılır. Hedef sonuçlar ve ürettiği sonuçların farkı alınarak hata değeri elde edilir ve bu değer ağıdaki bütün ağırlıklara dağıtılır.³⁸

DCNN ile sınıflandırma işlemini gerçekleştirmek için optimize edilmesi gereken çok sayıda parametre mevcuttur. Ağların iyileştirilmesi için giriş resminin boyutu, katman sayısı, filtre sayısı ve boyutu, aktivasyon fonksiyonu ve tam bağı katman sayısı gibi parametreler kullanılmaktadır. Bu iyileştirme işlemleri hiperparametre olarak ifade edilmektedir.^{18, 39, 40}

2.9. Aktivasyon Fonksiyonu

Sinir ağlarında veriler ağırlık değerleri ile çarpılarak transfer fonksiyonuyla birleştirilip aktivasyon fonksiyonundan geçmektedir. Aktivasyon fonksiyonları sinir ağlarında doğrusal olan ifadeleri doğrusal olmayan ifadelere dönüştürmeyi

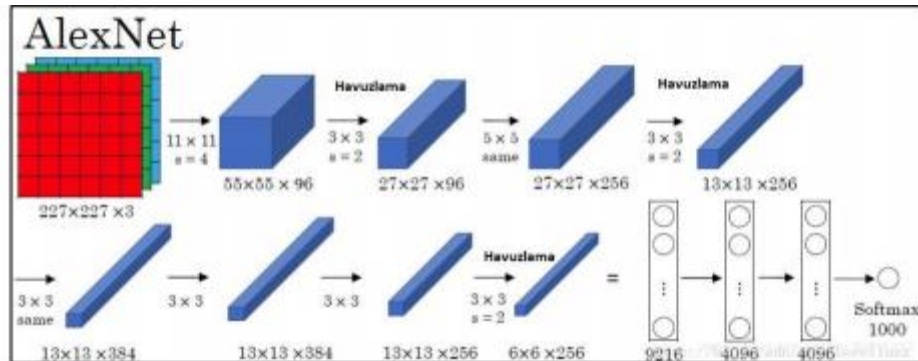
gerçekleştirerek ağı eğrisel fonksiyonları da öğrenebilmesi sağlar. Bu fonksiyonlar sinir ağlarının öğrenme sürecini etkilemektedir. Sigmoid, tanjant hiperbolik, ReLu ve Softmax genel olarak kullanılan aktivasyon fonksiyonlarıdır.^{18, 40}

2.10. Transfer Öğrenme

DCNN eğitiminde en büyük problem veri setinin az olduğu durumlardır. Transfer öğrenme; veri setinin yetersiz olduğu bu gibi durumlarda önceden eğitilmiş bir CNN modelini, gerçekleştirilen göreve göre değiştirerek, hedef veride ince ayar yapılmasını sağlayacak olan parametrelerin aktarılması işlemidir. Bu DCNN modellerine örnek olarak AlexNet, VGGNet, GoogleNet ve ResNet mimarileri verilebilir.^{18, 41}

2.10.1. AlexNet

2012 yılında ImageNet yarışmasında adını duyuran bu model, yaklaşık olarak bir milyonun üzerinde eğitilmiş görüntüye sahip olan resimleri sınıflandırmada oldukça yüksek performans gösteren bir derin öğrenme modelidir (Şekil 2.13).⁴²



Şekil 2.13. AlexNet mimarisi¹⁸

2.10.2. VGGNet

Grafik işlem birimi (GPU) destekli bir derin öğrenme modeli olan VGGNet, 2014 yılında düzenlenen ImageNet yarışmasında %89 başarı oranı yakalamıştır. Diğer modellere kıyasla ön plana çıkan özelliği ikili veya üçlü evrişim katmanlarının devamında havuzlama katmanının yer almasıdır (Şekil 2.14). VGGNet mimarileri AlexNet mimarisinden daha derin bir mimari yapıdadır.^{18, 43-45}



Şekil 2.14. VGG-16 mimarisi¹⁸

2.10.3. GoogleNet

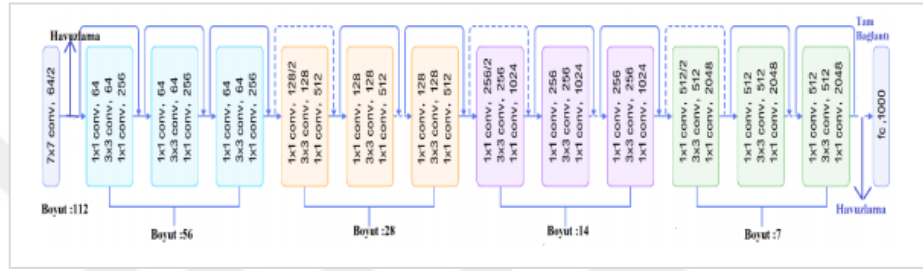
2014 yılında yapılan ImageNet resim yarışmasında birinci olan bu derin öğrenme modeli, 22 katmandan oluşmaktadır. Bu mimaride diğer derin öğrenme mimarilerinden farklı olarak katmanlar üst üste yığılarak değil paralel bir şekilde resim işlemektedir (Şekil 2.15).⁴⁶



Şekil 2.15. GoogleNet mimarisi⁴⁶

2.10.4. ResNet

ResNet mimarisinin ön plana çıkan özelliği katman sayısındaki fazlalıktır. GoogleNet mimarisindeki katman sayısından yaklaşık olarak 7 kat daha fazla katman içermektedir. 2015 yılındaki ImageNet resim sınıflandırma yarışmasında ResNet birinci olmuştur. “Residual” bloklar içeren bu derin öğrenme mimarisinin yapısı Şekil 2.16’da gösterilmiştir.⁴⁷



Şekil 2.16. ResNet mimarisi⁴⁷

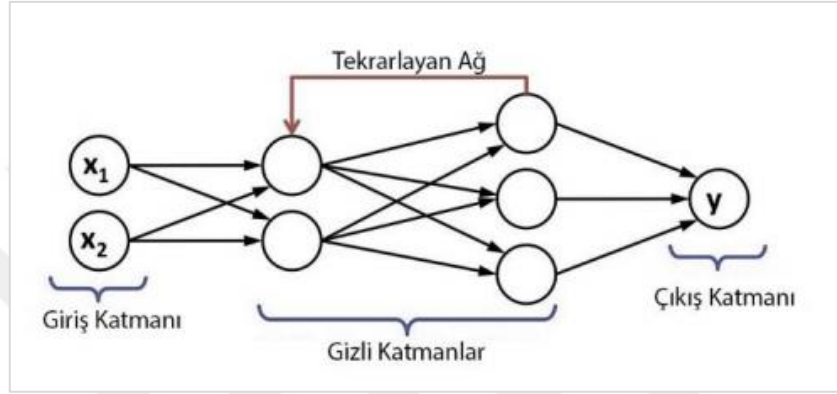
2.11. Derin Öğrenme Mimarileri

2.11.1. Evrişimli Sinir Ağları (Convolutional Neural Network-CNN)

Yaygın olarak kullanılan evrişimli sinir ağları çok katmanlı algılayıcılardan (Multi Layer Perceptron-MLP) türeyen bir mimaridir. Nesne tanıma ve görüntü işleme işlemlerinde oldukça başarılıdır.⁴⁸ CNN’den oluşan modellere örnek olarak AlexNet ve GoogleNet verilebilir.^{46, 49}

2.11.2. Tekrarlayan Sinir Ağları (Recurrent Neural Network-RNN)

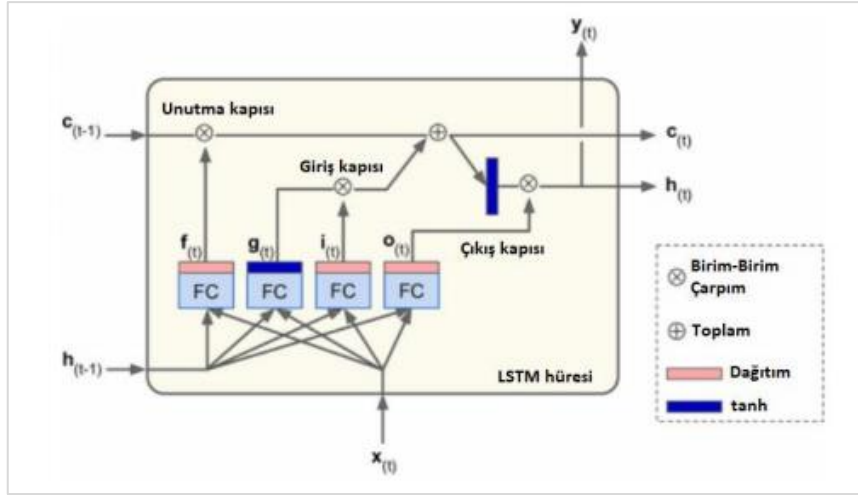
Tekrarlayan sinir ağları (RNN), sıralı bilgileri kullanarak gizli katman çıkışını tekrar aynı katmana giriş olarak geri gönderebilen bir DL mimari çeşididir.⁵⁰ RNN'de nöronların geriye dönük bağlantıları vardır bu sayede önceki girdilerin geçmişinden tüm çıktıya eşleme yapabilmektedirler.⁵¹ Şekil 2.17'de RNN modeli gösterilmiştir.



Şekil 2.17. RNN modeli⁵²

2.11.3. Uzun-Kısa Süreli Bellek Ağları (Long-Short Term Memory-LTSM)


Uzun-kısa süreli bellek ağları (LTSM) esas olarak uzun vadeli bilgilerin hatırlanması gereken durumlarda başarılı sonuçlar vermektedir. Var olan tahmini belirleyen önceki durum yakın tarihte değilse RNN ile başarılı sonuçlar alınamamaktadır.⁴¹ Bu sorunu çözmek için LTSM'nin gizli katmanlarında giriş kapısı, çıkış kapısı ve unutma kapısı olmak üzere üç adet kapısı mevcuttur. "Hücre" adı verilen bu kapılar bilgi akışını kontrol etmektedirler. Her adımda öğrenilen verilerin hangilerinin kalacağı hangilerinin güncelleneceğine karar verilmektedir.^{41, 53, 54} Şekil 2.18.'de LTSM ağ yapısı gösterilmiştir.



Şekil 2.18. LSTM ağ yapısı⁵¹

2.11.4. Derin Oto-Kodlayıcılar (Deep Autoencoders)


Denetimsiz bir DL mimarisi olan derin oto-kodlayıcılar esas olarak boyut indirgeme ve özellik çıkarımı fonksiyonları için kullanılmaktadır. Giriş ve çıkış düğümlerinin sayısı eşittir. Girdi verilerinin sıkıştırılarak en önemli özelliklerinin elde edildiği ileri beslemeli bir sinir ağı yapısına sahiptirler. Eğitimleri için etiketlenmiş veri gerekmemektedir ancak bir ön-eğitim aşamasına ihtiyaç vardır.^{32, 46, 55} Şekil 2.19.'da derin oto-kodlayıcı ağ modeli gösterilmiştir.



Şekil 2.19. Derin oto-kodlayıcı ağ modeli⁵⁵

2.11.5. Derin İnanç Ağları (Deep Belief Networks)


Derin inanç ağları her bir alt ağı gizli katmanının bir sonraki katman için görünür katman olduğu bir derin öğrenme mimarisidir. Eğitim süresi oldukça yavaş olan derin inanç ağlarında sistem denetimli veya denetimsiz şekilde uygulanabilmektedir. En üst seviyede (ilk iki katman) yönsüz bağlantılar mevcuttur.^{55,56} Bu modelde yüksek olasılıklı bilgilerin çıkarımı yapılmakta olup, eğitim aşaması maliyetlidir.^{56, 57} Şekil 2.20.'derin inanç ağı modeli gösterilmiştir.



Şekil 2.20. Derin inanç ağları modeli⁵⁵

2.11.6. Derin Boltzmann Makinesi (Deep Boltzmann Machine)

Derin Boltzmann makinesi yönteminin derin inanç ağlarından farkı tüm katmanlar arasında yönsüz bağlantıların varlığıdır.(Şekil 2.21.)⁵⁵



Şekil 2.21. Derin Boltzmann Makinesi modeli⁵⁵

2.12. Derin Öğrenmede Görüntü Segmentasyonu

AI bir görüntü üzerinde analiz yapabilmek için üç farklı teknik kullanır⁵⁸;

Sınıflandırma: Görüntüdeki bir öğenin hangi sınıfa ait olduğunu tahmin etmeyi ifade etmektedir. Örnek olarak görüntünün tamamının “insanlar”, “hayvanlar” veya “açık hava” gibi sınıflara ayrılması verilebilir.^{59, 60}

Nesne algılama: Bir görüntüdeki nesnelere tespit etmeyi ve ilgili nesneyi dikdörtgen bir çerçevenin içine almayı (dikdörtgen çizmek) ifade etmektedir (örneğin bir kişi veya bir koyun).^{59, 61}

Segmentasyon: Görüntüdeki bir yapıyı geri kalanından ayırmayı ifade etmektedir. Görüntünün sınırlarıyla birlikte hangi nesneye ait olduğunu göstermektedir (Örneğin bir organın sınırlarının belirlenmesi, bilgisayarlı tomografide (BT) pulmoner embolinin belirlenmesi).^{44, 59} Bu teknikte nesnelere ve nesne parçalarını “süper pikseller” oluşturur. Segmentasyon tekniği, tek tek pikselleri gözlem birimleri olarak değerlendirmek yerine daha büyük bileşenler şeklinde çalışmayı sağlar.⁶²

Tam evrişimli ağlar, grafik modellenmiş evrişimli modeller, çok ölçekli ve piramit ağ tabanlı modeller, R-CNN tabanlı modeller, genişletilmiş evrişimli modeller, tekrarlayan sinir ağı tabanlı modeller, dikkat tabanlı modeller, aktif kontur modelleri ile evrişimli modeller, kodlayıcı-kod çözücü tabanlı modeller DL tabanlı segmentasyon modellerine örnek olarak verilebilir.⁵⁸

2.12.1. Kodlayıcı-Kod Çözücü Modeller

Kodlayıcı-kod çözücü modeller görüntü bölümlenmede yaygın olarak kullanılan modellerdir ve birçok DL temelli segmentasyon çalışmasında kullanılmıştır. En iyi bilinenler arasında U-Net ve V-Net derin öğrenme mimarileri bulunmaktadır.^{58, 62, 63}

2.12.2. U-Net ile Görüntü Segmentasyonu

Bir CNN yöntemi olan U-Net mimarisi medikal görüntüler üzerinde görüntü segmentasyonunda en başarılı olan yöntemlerden biridir. U-Net mimarisi kodlama ve kod çözme bölümlerinden oluşmaktadır, kodlama işlemi VGG tarzı bir CNN modelinden oluşur, kod çözme ise, özellik kanalını yukarı evrişimin tekrarlanarak uygulanmasıyla gerçekleşmektedir.^{43,64}

U-Net mimarisi ile sınırlı miktarda eğitim verisi kullanarak görüntüler üzerinde başarılı bir şekilde segmentasyon yapılabilmektedir. Bu sebeple medikal alanda görüntü segmentasyonunda sıklıkla kullanılmaktadır.⁶⁵

2.13. Derin Öğrenme Kütüphaneleri

DL mimarilerinin hızlı bir şekilde gelişebilmesine katkısı olan en önemli etken, bu alan için oluşturulmuş olan kütüphanelerin varlığıdır. Çeşitli programlama dilinde (Java, C#, C++, Python vb.) olan bu kütüphane dosyaları CNN, RNN ve ileri besleme ağları gibi birçok modeli destekleyici niteliktedir.⁶⁶

Caffe: Önceden eğitilen modellere sahip olan Caffe kütüphanesi, görüntü işleme ve DL algoritmaları için uygulanan bir kütüphanedir. Python, Matlab gibi uygulama dillerinde de çalıştırılabilmektedir.⁶⁷

Keras: Yüksek seviyeli bir derin öğrenme kütüphanesi olan Keras; Python programlama dili üzerine yazılmıştır.⁶⁶

TensorFlow: Açık kaynak kodlu bir kütüphane olan TensorFlow genellikle görüntü işleme ve sayısal hesaplamalar için kullanılmaktadır.⁶⁶

Torch: Lua ve Python programlama dilleri ile desteklenen Torch kütüphanesi; görüntü ve ses işleme, video, resim formatları üzerinde kullanılabilir.⁶⁶

MXNet: R, Python, Scala, Julia programlama dilleri ile desteklenen ve bu yüzden birçok dil desteği sağlayan bir kütüphane olması açısından önemlidir.⁶⁶

2.14. Diş Hekimliğinde Yapay Zekâ ve Kullanım Alanları

AI uygulamaları diş hekimliğinin birçok alanı için popüler hale gelmeye başlamıştır. AI teknolojisinin diş hekimliği alanında kullanılmaya başlanması; zamandan ve maliyetten tasarruf yapmayı sağlar, insan kaynaklı hataları azaltır. İnsan zekâsını taklit eden bu sistem ile medikal bilgiler incelenebilir, düzenlenebilir ve sınıflandırılabilir.^{68, 69}

2.14.1. Ağız, Diş ve Çene Radyolojisi Alanında Yapay Zekâ

AI ağız, diş ve çene bölgesinde bir insan gözüne kıyasla daha hassas bir değerlendirme yapabilmektedir.⁷⁰ Diş hekimliği radyolojisinde; diş tespit ve segmentasyonu, ekstra kök ve süpernümerer diş tespiti, vertikal kök kırığı tespiti, apikal lezyon tespiti, osteoporoz tanısı konulmasında, Sjögren sendromu tespiti ve ultrasonografi alanında CNN'den faydalanılmıştır.⁷¹⁻⁷⁷

AI diş tespit ve segmentasyonunda birçok çalışmada kullanılmıştır. DCNN'ler kullanılarak panoramik radyografiler^{74, 78}, periapikal radyografiler⁷³ ve bite-wing radyografiler⁷⁹ üzerinde diş tespit ve segmentasyonu için DL destekli AI modelleri üzerinde çalışılmıştır ve sonuçlar umut vadedicidir. Diş numaralandırma ve segmentasyon çalışmaları KIBT üzerinde de yapılmıştır.⁸⁰⁻⁸²

Ağız, diş ve çene radyolojisi alanında AI apikal lezyon tespitinde de kullanılmıştır. Ekert ve ark.⁷¹ yaptıkları bir çalışmada DCNN'yi kullanarak panoramik radyografilerde apikal lezyon tespiti yapmışlardır ve sistem %65 oranında duyarlılık göstermiştir.

Periapikal radyografilerde üzerinde yapılan başka bir çalışmada ise Ruben ve ark.⁸³ geliştirdikleri AI sisteminin %80'in üzerinde başarı gösterdiğini ifade etmişlerdir. Orhan ve ark.⁷⁵ yaptıkları bir çalışmada, KIBT üzerinde periapikal patolojilerin tespitini gerçekleştiren bir AI modeli geliştirmişlerdir ve AI modelinin toplamda 153 periapikal lezyonun 142'sini başarıyla tespit ettiğini bildirmişlerdir.⁷⁵

Radyoloji alanında lenf nodu metastaz tespiti, Sjögren sendromu ve osteoporoz gibi hastalıkların tespitinde de AI algoritmaları kullanılmıştır. Hiraiwa ve ark.⁸⁴ yaptıkları bir çalışmada Sjögren sendromunun tespiti için BT görüntüleri üzerinde çalışma yapmışlardır ve geliştirilen model %96 oranında doğruluk göstermiştir.⁸⁴ Lee ve ark.⁸⁵ ise, osteoporoz tespiti için panoramik radyografiler üzerinde DCNN kullanarak bir model geliştirmişlerdir ve %98.5 oranında doğruluk oranı elde ederek geliştirilen AI sisteminin tahminlerinin, maksillofasiyal radyoloji uzmanları ile uyumlu olduğunu bildirmişlerdir.

Orhan ve ark. CNN'ne dayalı bir yöntem ile ultrasonografi görüntülerinde masseter kasının segmentasyonunu gerçekleştirmişlerdir. Çalışmada üç farklı DL modeli (U-Net, Pyramid Scene Parsing Network (PSPNet) ve Fuzzy Petri Net (FPN)) uygulanmış olup sırasıyla %96, %94, %98 değerlerinde yüksek oranda doğruluk elde edilmiştir.⁷⁷

2.14.2. Ortodonti Alanında Yapay Zekâ

Ortodonti alanında AI tanı tedavi analizleri, landmark tespiti, çekimli-çekimsiz ortodontik tedavi, iskeletsel sınıflandırma, büyüme gelişim döneminin belirlenmesi ve ortognatik cerrahi gibi birçok analiz için kullanılabilir. Yapılan çalışmalar, ortodonti alanında da DL algoritmalarının tanı ve tedavi sürecinde hekime destek olabileceğini göstermektedir.⁸⁶⁻⁹²

Xie ve ark.⁸⁶ AI algoritmaları ile lateral sefalometrik radyografiler üzerinde ortodontik tedavi öncesi diş çekim ihtiyacını değerlendirmişlerdir ve ortaya çıkan sonuçların umut vaat edici olduğunu belirtmişlerdir. AI'dan ortodonti alanında ayrıca anatomik landmark tespiti çalışmalarında da faydalanılmıştır. Yapılan bir çalışmada geliştirilen AI modeli ve diş hekimi arasında elde edilen sonuçlarda anlamlı bir fark tespit edilmediği bildirilmiştir.⁹³ Yu ve ark.⁹⁰ ise, otomatik olarak iskeletsel sınıflandırma için bir AI modeli üzerinde çalışmışlardır. Ortaya çıkan modelin yüksek performans gösterdiğini, %90 oranında duyarlılık, doğruluk ve özgüllük değerleri elde ettiklerini bildirmişlerdir.

AI ile ortognatik cerrahi planlamasında da başarılı sonuçlar elde edilmiştir. Choi ve ark.⁹¹ yaptıkları bir çalışmada cerrahi gerektiren ve gerektirmeyen olmak üzere ortodontik tedavi yapılacak hastaların teşhisi için AI modeli geliştirmişlerdir. Model yüksek performans göstermiştir ve %96 oranında başarı elde etmişlerdir.⁹¹ AI ortodonti alanında ayrıca büyüme gelişim dönemlerinin tespit edilmesinde de kullanılmıştır. Bu evrelerin belirlenmesi genellikle el-bilek ve lateral sefalometrik radyografiler aracılığıyla yapılmaktadır.⁹⁴ Yapılan bir çalışmada AI modeli ile sefalometrik radyografilerde servikal vertebralar incelenerek büyüme gelişim döneminin tespiti yapılmıştır. AI algoritmalarının, büyüme gelişiminin belirlenmesi gereken tüm bilim dallarında teşhis amaçlı kullanılabileceği bildirilmiştir.⁹²

2.14.3. Ağız, Diş ve Çene Cerrahisi Alanında Yapay Zekâ

AI cerrahi alanında robotik uygulamalar sayesinde popülerlik kazanmıştır. Cerrahi operasyon henüz gerçekleşmeden, olası komplikasyonların önüne geçilmesi amacıyla anatomik landmarkların detaylı olarak tespiti yapılabilmektedir. Bu sayede hem önemli

anatomik yapılar korunmuş olup hem de operasyon daha kısa sürede bitirilmiş olmaktadır.^{95, 96} AI teknolojisi ağız, diş ve çene cerrahisi alanında diş çekimi işlemleri sonrasında post-operatif dönemdeki şişliği tahmin etmek için de kullanılmıştır. Zhang ve ark.⁹⁷, gömülü mandibular üçüncü molar dişlerin çekiminin ardından post-operatif yüz şişliğini tahmin etmek için bir AI modeli üzerinde çalışmışlardır. Model yüksek performans göstermiş ve %98 oranında doğruluk elde ettiklerini bildirmişlerdir.⁹⁷ Orhan ve ark.⁹⁸ KIBT görüntüleri üzerinde yaptıkları bir çalışmada AI modeli aracılığıyla gömülü üçüncü molar dişlerin tanısal doğruluğunu değerlendirmişlerdir. Sonuç olarak geliştirilen modelin gömülü üçüncü molar dişlerin tespitinde ve anatomik yapılarla olan ilişkilerinin değerlendirilmesinde %86.2 oranında doğruluk performansı gösterdiğini belirtmişlerdir.⁹⁸ Bir başka çalışmada ise panoramik radyografiler üzerinde DCNN kullanılarak üçüncü molar dişlerin çekim zorluğu değerlendirilmiştir. Çekim zorluğu Pederson zorluk skoru (PDS) kullanılarak üç gözlemcinin fikir birliğine göre değerlendirilmiştir. Gömülü üçüncü molar dişlerin; ramusla ilişkisinin, angulasyonunun ve ayrıca mandibular ikinci molar referans alınarak belirlenen derinlik bilgisinin belirlenmesi ile ilgili sırasıyla %82.03, %90.23 ve %78.91 oranlarında başarı elde edilmiştir.⁹⁹

2.14.4. Restoratif Diş Hekimliği Alanında Yapay Zekâ

Diş çürüklerinin görülme oranının yaşadığımız dönem içerisinde önceki dönemlere göre azaldığı belirtilmektedir. Bunun sebebi olarak florür kullanımının ve diğer önleyici yöntemlerin popülerlik kazanması olduğu düşünülmektedir. Bu durum çürük tespitini daha zor hale getirmiştir. Bu nedenle bite-wing radyografiler tespiti zor ara yüz çürüklerinin teşhisinde çok önemli bir yere sahiptir.¹⁰⁰⁻¹⁰² Ancak bite-wing

radyografilere rağmen çürük teşhisi zor olabilmektedir.¹⁰³ Bu nedenle son yıllarda bilgisayar destekli programlara talep artmıştır.¹⁰⁴⁻¹⁰⁶

Srivastava ve ark. yaptıkları bir çalışmada geliştirdikleri AI modeli ile, üç tecrübeli diş hekiminin çürük tanısı koymadaki performansını kıyaslamışlardır. Geliştirilen otomatik sistem çalışmadaki diş hekimlerinden daha başarılı performans göstermiştir.¹⁰⁷ Benzer bir çalışmada da bite-wing radyografilere derin öğrenme yöntemine dayalı bir model geliştirilerek çürük lezyonu tespiti üzerine çalışılmıştır. Sonuç olarak geliştirilen AI modeli, çalışmada %71 oranında doğru tahminde bulunan diş hekimlerine kıyasla %80 doğruluk oranı ile daha yüksek başarı göstermiştir.¹⁰⁸ Askar ve ark. ise, dental fotoğraflar üzerinde bir derin öğrenme yaklaşımına dayalı yöntem ile beyaz nokta lezyonlarının tespitini gerçekleştirmiştir. Sistem %80'in üzerinde doğruluk göstermiştir.¹⁰⁹ Casalegno ve ark. ise, yaptıkları bir çalışmada translüminasyon görüntülerinde çürüğün otomatik olarak algılanması ve lokalizasyonu için bir AI modeli geliştirmişlerdir. %72.7'lik bir başarı elde etmişlerdir.¹¹⁰ Lee ve ark.¹¹¹ ise, DCNN kullanarak periapikal radyografilere çürük tespiti üzerine premolar ve molar dişler üzerinde bir çalışma yapmışlardır. En yüksek başarıyı %89'luk bir oran ile premolar dişlerde elde etmişlerdir. DL destekli AI modellerinin önümüzdeki yıllarda etkili bir çürük teşhis yöntemi olacağını belirtmişlerdir.¹¹¹

2.14.5. Periodontoloji Alanında Yapay Zekâ

Periodontal hastalıklar diş kayıplarıyla sonuçlanabilen, yaygın görülen bir hastalık grubunu oluşturmaktadır.¹¹² AI ve DCNN sayesinde periodontoloji alanında da birçok çalışma yapılmıştır. Alveoler kemik kaybının belirlenmesi ve kemik densitesindeki değişiklikler AI modeller aracılığıyla erken olarak tespit edilebilmektedir. Ayrıca implant

ve çevre dokular ile ilgili erken müdahale gerekebilecek durumlarda da derin öğrenme yöntemlerinden faydalanılabileceği düşünülmektedir.¹¹³⁻¹¹⁵

Lee ve ark.¹¹⁵ periodontal hastalık sebebiyle prognozu en kötü olan dişleri tespit etmek amacıyla bir AI modeli geliştirmişlerdir ve %78.9'luk bir doğruluk oranı elde etmişlerdir. Alalharith ve ark.¹¹⁶ ise, ortodontik tedavi gören hastalar ile yaptıkları bir çalışmada periodontal hastalığın otomatik olarak tespitini gerçekleştirmişlerdir. Başarı oranının %77.12 olduğunu bildirmişlerdir.¹¹⁶ Bir başka çalışmada ise DCNN kullanılarak panoramik radyografilerde periodontal alveolar kemik kaybının tespiti üzerine bir çalışma yapılmıştır. Geliştirilen AI modelinin bulduğu sonuçların uzman bir diş hekimiyle %81 oranında örtüştüğünü tespit etmişlerdir.⁷¹

Cha ve ark. geliştirdikleri bir AI modeli ile periapikal radyografilerde implant tespiti yapmışlar ve etrafındaki kemik kaybını değerlendirmişlerdir. Çalışmadaki diş hekimleri ile modelin sonuçları arasında anlamlı bir fark saptamadıklarını bildirmişlerdir. Modelin, peri-implantitisi tespit etmek için kullanılabileceğini belirtmişlerdir.¹¹⁷

Dental implant fraktürü nadir görülen mekanik bir komplikasyondur. Lee ve ark. yaptıkları bir çalışmada panoramik ve periapikal radyografiler üzerinde dental implantlardaki fraktürlerin tespiti için kullandıkları üç farklı DL sistemini değerlendirmişlerdir. Üç sistemde de %80'in üzerinde bir doğruluk oranı elde edilmiştir.¹¹⁸

AI implant planlaması alanında da kullanılmıştır. Bayrakdar ve ark.¹¹⁹ yaptıkları bir çalışmada KIBT görüntüleri üzerinde AI sisteminin implant planlamasındaki başarısını araştırmışlardır. Yetmiş beş KIBT görüntüsü üzerinde kanalların, sinüs/fossaların ve eksik diş bölgelerinin tespitini gerçekleştirmişlerdir. Sistem en yüksek oranda (%95.3) eksik diş bölgesi tespitinde olmak üzere başarılı sonuçlar vermiştir.

Yazarlar AI algoritmalarının klinik rutininde implantoloji alanında hekimlere bir destek mekanizması olacağını belirtmişlerdir.

2.14.6. Ağız Kanserleri ve Yapay Zekâ

AI ile oral mukozada görülen iyi huylu ve kötü huylu lezyonların sınıflandırılması yapılabilmektedir. Şüpheli bölgelerin taranması ve tespiti bu algoritmalar sayesinde mümkün hale gelmiştir. Özellikle geniş çaptaki ağız taramalarında kullanılarak değerlendirilen popülasyonun ağız kanserlerine yatkınlığını tahmin edebileceği düşünülmektedir.^{120, 121}

Oral bölgede tespit edilen skuamöz hücreli karsinomların prognozunu etkileyen en önemli faktörlerden biri erken teşhistir. Ancak yine de birçok vakanın teşhisi ileri evrede konulmaktadır. Sağlık hizmetlerinin kısıtlı olduğu birçok bölgede AI destekli yazılımlar ile yapılacak olan taramalar sayesinde morbidite ve mortalite oranlarının düşürüleceği düşünülmektedir.^{122, 123}

Rosmai ve arkadaşları geliştirdikleri AI modeli ile bireylerin oral kansere yakalanma olasılığını değerlendirmişlerdir. Geliştirilen AI modelinin tahminleri bir grup oral kanser klinisyeninin tahminleriyle kıyaslanmıştır. Sonuç olarak %59.9 oranında doğruluk elde edilmiştir.¹²¹

Shamim ve ark. yaptıkları bir çalışmada derin öğrenme yöntemine dayalı geliştirdikleri bir AI modeli ile prekanseröz dil lezyonlarının tespitini gerçekleştirmişlerdir. Bu DCNN'ye dayalı yöntemin %98 doğruluk, %89 duyarlılık ve %97 özgüllük gösterdiğini bildirmişlerdir.¹²⁴

2.14.7. Adli Diş Hekimliği Alanında Yapay Zekâ

Adli diş hekimliği kimlik tespit çalışmaları açısından diş hekimliğinin önemli bir alanıdır.¹² Do Tobel ve ark.¹²⁵ panoramik radyografiler üzerinde mandibular üçüncü molar dişlerin evrelendirilmesinde bir AI model üzerinde çalışmışlardır ve mandibular üçüncü molar dişleri evrelendirerek yaş tahmini yapmışlardır. Geliştirilen AI modelinin %51 oranında doğru sonuçlar verdiğini bildirmişlerdir. Patil ve ark.¹²⁶ ise, panoramik radyografiler üzerinden cinsiyet tahmini için bir AI modeli geliştirmişlerdir. ANN kullanılarak geliştirilen bu sistemin sonuçlarının ümit verici (%75 doğruluk) olduğunu belirtmişlerdir. Bir başka çalışmada ise, mandibular morfolojiyi tahmin etmek için ANN'ye dayalı bir sistem üzerinde çalışılmıştır ve başarılı sonuçlar (%95 doğruluk) elde edilmiştir.¹²⁷

2.15. Konik Işınlı Bilgisayarlı Tomografi (KIBT)

KIBT maksillofasiyal bölgedeki yapıların üç boyutlu (3B) olarak görüntülenmesini sağlayan değerli bir görüntüleme yöntemidir.¹²⁸ Bu bölgedeki yapıların incelenmesine olanak veren BT'ye kıyasla KIBT; maliyetinin ve hasta radyasyon dozunun düşük olması ve daha hızlı veri elde edilmesi gibi avantajlara sahiptir.¹²⁹ KIBT ilk defa 1982'de anjiyografide kullanılmıştır.¹³⁰ Diş hekimliği için geliştirilen ilk KIBT cihazı 1998 yılında üretilen "NewTom" isimli cihazdır.¹³¹

KIBT'de konik şekilli X-ışını kullanılır ve maksillofasiyal bölgenin tamamının rekonstrüksiyonu yapılabilmektedir.^{132, 133} KIBT iki boyutlu (2B) dedektör üzerine 3B konik şekilli X-ışını demetinin yönlendirilmesi ile gerçekleşen bir görüntüleme tekniğidir. Hastanın başı sabit olmakla birlikte, başın etrafında eş zamanlı olarak dönen X-ışını kaynağı ve alan dedektörü ile 360 derecelik tarama yapılır. Kullanılan cihaza ve

prosedüre bağılı olarak tarama zamanı 5 ile 40 saniye arasında deęişmektedir. Projeksiyon verilerinden yazılım programları aracılıęıyla multiplanar (aksiyal, sagittal ve koronal) ve üç boyutlu görüntüler elde edilmektedir.^{131, 134}

KIBT’de hacimsel verinin en küçük birimine “voksel” denmektedir. Bu cihazlarda vokseller izotropiktir (küp şeklinde). Bu nedenle x , y ve z eksenlerinde boyutları eşittir. Görüntü çözünürlüğü üzerinde önemli bir etkisi olan voksellerin boyutu azaldıkça çözünürlük artmaktadır. Ayrıca boyutları cihazdan cihaza farklılık göstermekle birlikte 0.125 ile 0.4 mm arasında deęişmektedir.^{131, 134, 135}

Dış hekimliğinde KIBT’nin kullanım alanları;

- Büyüme ve gelişimin deęerlendirilmesi
- Maksillofasiyal anomalilerin deęerlendirilmesi
- İmplantoloji
- Patolojilerin boyut ve lokalizasyonun deęerlendirilmesi
- Kök-kanal morfolojilerinin incelenmesi ve patolojilerin belirlenmesi
- Gömülü dişlerin lokalizasyonlarının ve komşu anatomik yapılarla ilişkisinin deęerlendirilmesi
- Mandibular kanalın deęerlendirilmesi
- Aksesuar kanalların varlığının deęerlendirilmesi
- Temporomandibular eklemin (TME) morfolojisinin ve patolojilerinin deęerlendirilmesi
- Paranasal sinüslerin deęerlendirilmesi
- Hava yolu analizi
- Dudak-damak yarıklarının deęerlendirilmesi şeklinde sıralanabilir.^{131, 135-143}

3. MATERYAL VE METOT

3.1. Hasta Seçimi

Bu çalışmada çeşitli sebeplerle Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesine başvuran hastaların KIBT verileri kullanıldı. Veri setini Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı radyografi arşivinden Ocak 2016 - Nisan 2020 tarihleri arasından seçilen 103 adet anonimleştirilmiş KIBT görüntüsü oluşturmaktadır. Restoratif dolgu materyali, kök-kanal tedavili dişleri olan hastalar çalışmaya dâhil edildi. Görüntü kalitesi kötü olan radyografik görüntüler (metal artefaktı, çekim sırasında oluşan pozisyon hataları kaynaklı artefaktlar vb. sebeplerle meydana gelen bozukluklar) ve kraniofasiyal sendromu, dudak damak yarığı, kraniofasiyal bölge kemik hastalıkları ve diş eksikliği olan, ortognatik cerrahi görmüş hastaların, protetik restorasyona, dental implanta sahip hastaların radyografik görüntüleri çalışmaya dâhil edilmedi.

Çalışma protokolü Eskişehir Osmangazi Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Komitesi tarafından onaylandı (karar tarihi ve numarası:12.05.2020/17). 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 sn ve voksel boyutu 0.600 mm'dir. Çalışmada 103 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. Elde edilen aksiyel çerçeve görüntülerinden dişlerin bulunmadığı kesitler çıkarıldı. Geriye kalan 3649 adet aksiyel görüntüsü CranioCatch etiketleme yazılımına (Eskişehir, Türkiye) yüklenerek proje oluşturuldu.


3.3. Görüntü Değerlendirmesi

Etiketleme, bir görüntüdeki alanların tanımlanması ve nesnenin tanımlanan hangi bölgeye ait olduğunun belirlendiği işlemdir. Yüz üç hastadan elde edilen aksiyel görüntüler 1024 x 1024 piksel boyutuna yeniden boyutlandırıldı. Aksiyel kesit görüntüleri üzerindeki dişler; 3 yıllık deneyime sahip bir araştırma görevlisi ve 11 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanı tarafından CranioCatch (Eskişehir, Türkiye) yazılımı kullanılarak Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Dental AI 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.

Etiketleme KIBT görüntüleri üzerinde dişlerin dış sınırlarının serbest çizim tekniği ile belirlenerek çizilmesi şeklinde (poligon yöntemi) gerçekleştirildi.

Diş tipleri için 32 farklı numara (11, 12, 13, 14, 15, 16, 17, 18, 21, 22, 23, 24, 25, 26, 27, 28, 31, 32, 33, 34, 35, 36, 37, 38, 41, 42, 43, 44, 45, 46, 47, 48) kullanıldı. Dişler,


FDI (Federation Dentaire Internationale: Dünya çapında diş hekimliğinde daimî diş numaralandırmada kullanılan sistem) sistemine göre sınıflandırıldı (Şekil 3.1., 3.2., 3.3.).



Şekil 3.1. Üst çenede dişlerin poligonal tarzda etiketlenmesi



Şekil 3.2. Alt çenede dişlerin poligonal tarzda etiketlenmesi



Şekil 3.3. Poligonal tarzda etiketlenen 46 nolu dişin görüntüsü

3.4. Derin Öğrenme Mimarisi

Derin öğrenme TensorFlow 1 kütüphanesi ve Python açık kaynak programlama dili (v.3.6.1; Python Software Foundation, Wilmington, DE, ABD) destekli transfer öğrenme teknikleriyle gerçekleştirildi. Dişleri tespit etme ve numaralandırma için transfer öğrenme tekniği ile önceden Microsoft Common Objects in Context (MS COCO)¹⁴⁴ veri seti ile eğitilmiş mimariler olan Inception v2, ResNet-101 ve Inception ResNet v2 mimarileri kullanılmıştır ve performansları karşılaştırılmıştır.

ResNet-101, ResNet mimarisinin 101 adet katmandan oluşan versiyonudur. ResNet'in en önemli özelliği katmanlar arasında yaptığı atlama işlemidir. Bu işlem 'ResBlock' olarak adlandırılmaktadır. Böylelikle önceki katmanda bir şey öğrenilirse bile eski katmandaki bilgi yeni katmana uygulanarak model daha güçlü bir mimari olma özelliği kazanmıştır.¹⁴⁵

GoogleNet ekibi tarafından geliştirilen Inception mimarilerini diğer mimarilerden ayıran en önemli özellik ise, büyük evrişimler yapmak yerine daha küçük boyutta aynı görevi görebilecek filtreler kullanmasıdır. Böylece yapılan işlem miktarı azalmaktadır.¹⁴⁶ Model aynı katman içinde çeşitli evrişim filtreleri uygulayan 22 katmandan oluşan bir

mimaridir. Bir sınıflandırıcı, tamamen birbirine bağlı katmanlar ve softmax fonksiyonları dahil olmak üzere toplam dokuz başlangıç (Inception) modülü içermektedir.¹⁴⁷ Inception v1 (GoNet) 5x5 boyutunda filtreler kullanırken Inception v2 modeli 3x3'lük ardışık 2 filtre kullanmaktadır. Bu şekilde hesaplama yükünde azalma sağlanarak model iyileştirilmiştir.¹⁴⁷

Inception ResNet modeli ise, Faster R-CNN mimarisi kapsamında geliştirilmiş bir modeldir. Residual bloklar ve Inception mimarilerinin birleştirilmiş halidir. İki farklı modelin iç içe olduğu bu mimaride Residual blokların da avantajından yararlanılarak hesaplama verimliliği artırılmıştır.¹⁴⁸ Çalışmamızda eğittiğimiz versiyonu Inception ResNet v2'dir. Bu versiyonda birinci versiyonundan farklı olarak katman başına filtre sayısı artırılmıştır.¹⁴⁹

3.5. Model Geliştirilmesi

Python açık kaynak programlama dili (v.3.6.1; Python Software Foundation, Wilmington, DE, ABD) ve TensorFlow 1 kitaplığı model geliştirme için kullanıldı. Çalışmamızda modellerin eğitimi, 16 GB RAM ve NVIDIA Tesla V100 ekran kartı ile donatılmış bir bilgisayarda gerçekleştirildi.

3.6. Eğitim Aşaması

Eğitimden önce her bir aksiyel çerçeve 1024×1024 piksele yeniden boyutlandırıldı. Aksiyel kesit görüntüleri öncelikle ön eğitim sürecinde alt çene, üst çene ve orta (her iki çenenin kesiştiği kesitler) olmak üzere 3 farklı sınıfa gruplandırıldı. Elde

edilen çene sınıflandırma modeli %94'lük başarı gösterdi. Ancak iki nedenden dolayı bu model çalışmaya dâhil edilmedi;

- Birincisi modelin görüntünün hangi çeneye ait olduğu ile ilgili yaptığı tahminin %6'lık hata payına sahip olmasıydı,
- İkinci neden ise veri setinin değerlendirileceği model sayısı artışına paralel hesaplama yükünün ve eğitim süresinin artışı olmuştur. Bu nedenle görüntüler herhangi bir ön eğitimden geçirilmeden direkt olarak DL mimarilerinin eğitimi ve testi için kullanılmıştır.

Eğitim veri seti: Modelin eğitimi için kullanılan veri setini ifade etmektedir.⁴¹

Doğrulama veri seti: Modelin eğitiminden bağımsız olan ve bu süre boyunca modelin görmemesi gereken örnekleri ifade etmektedir. Eğitimin durdurulması veya eğitim değişkenlerinin revize edilmesi için model bu veri kümesinde sınanmaktadır.⁴¹

Test veri seti: Eğitim ve doğrulama verilerinden faydalanılarak eğitilen modelin sınamasının yapıldığı veri setini oluşturmaktadır.⁴¹

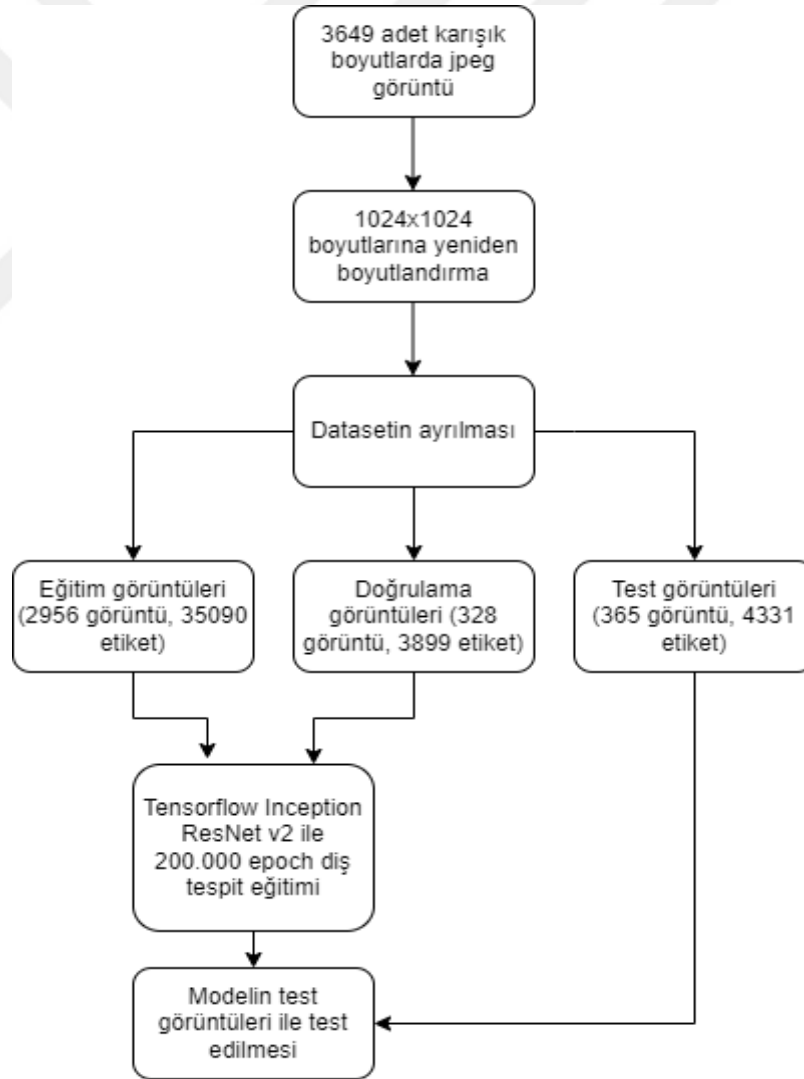
Eğitim ve doğrulama veri setleri optimal CNN algoritması ağırlık faktörlerini tahmin etmek ve üretmek için kullanıldı. Test veri setiyle de modellerin başarılarının değerlendirilmesi yapılmıştır. Veri setinin yaklaşık olarak %10'u test, %10'u doğrulama, %80'i de eğitim veri seti olarak ayrılmıştır (Tablo 3.1.).

Tablo 3.1. Veri seti sınıflandırması

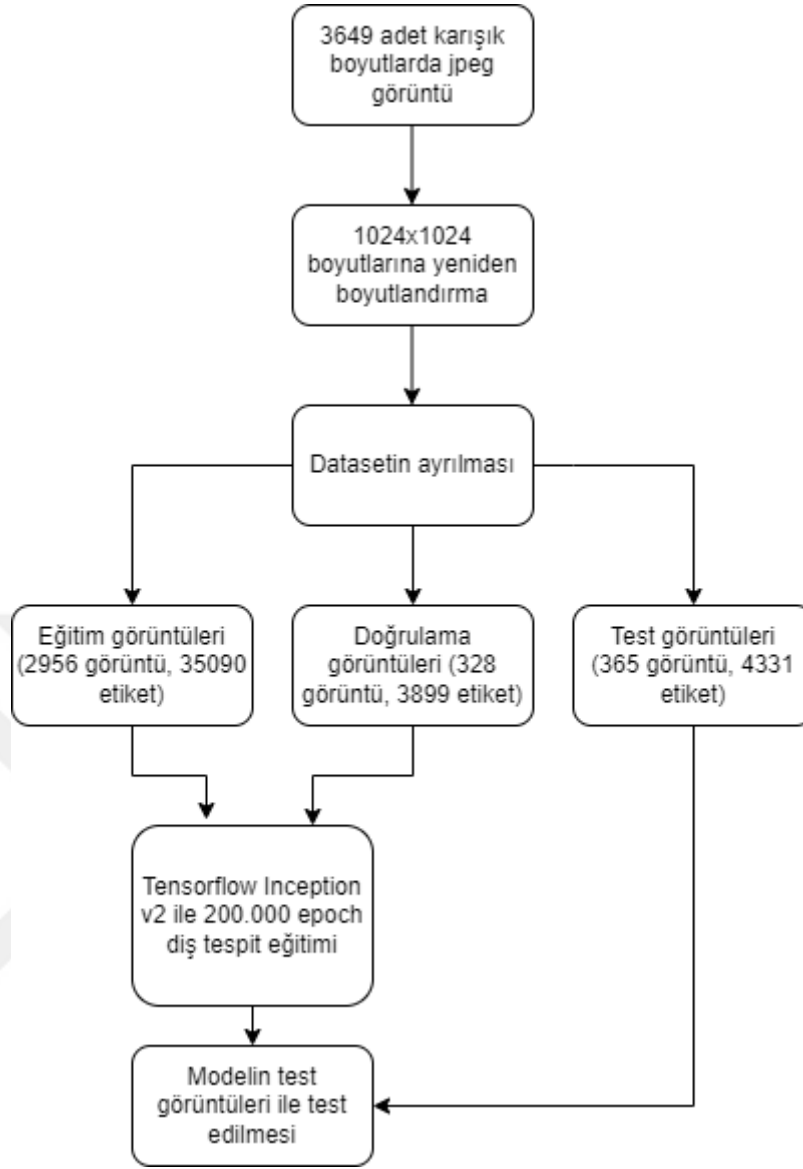
Eğitim veri seti	2956 Görüntü	35090 Etiket
Doğrulama veri seti	328 Görüntü	3899 Etiket
Test veri seti	365 Görüntü	4331 Etiket

Diş Tespit Eğitimi

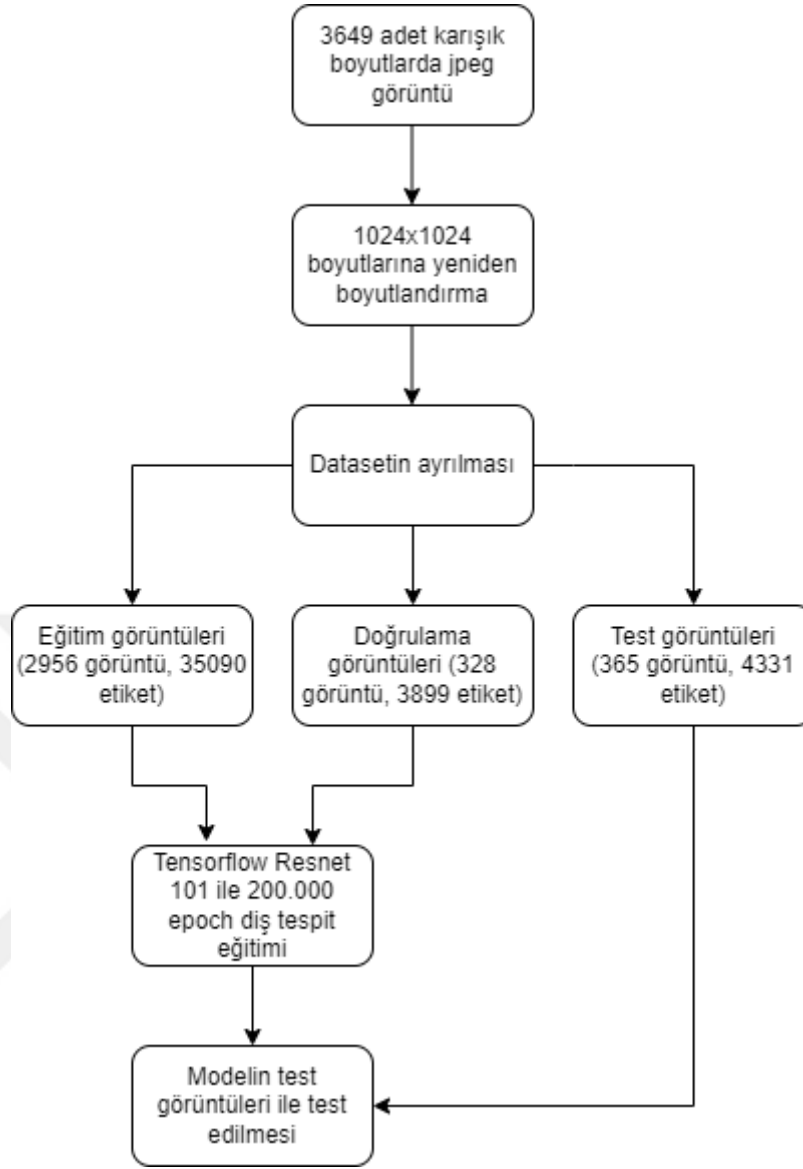
Aksiyel kesit çerçeveler üzerinde 32 farklı dişin etiklendiği eğitim veri seti 2956 adet görüntüden oluşmaktadır. Eğitim grubundaki 2956 aksiyel görüntü üzerinde 35090 diş etiklendi. Modellerin tümünün eğitimi 200.000 epoch (eğitim tur sayısı) yapılarak gerçekleştirildi (Şekil 3.4., 3.5.,3.6.). Inception ResNet v2, Res-Net-101 ve Inception v2 modellerinin öğrenme hızları (learning rate) ise sırasıyla; 0.0003, 0.0003 ve 0.0002 değerlerindedir. Eğitilen modellerin diş tespiti için oluşturduğu tahmini görüntüler (Şekil 3.7.,3.8.,3.9.).




Şekil 3.4. Inception ResNet v2 mimarisi ile gerçekleştirilen diş tespit modelinin gelişim aşamalarının diyagramı




Şekil 3.5. Inception v2 mimarisi ile gerçekleştirilen dış tespit modelinin gelişim aşamalarının diyagramı




Şekil 3.6. ResNet-101 mimarisi ile gerçekleştirilen dış tespit modelinin gelişim aşamalarının diyagramı



Şekil 3.7. AI algoritmalarının diş tespiti için oluşturduğu tahmini görüntüler (TP, gerçek pozitif)



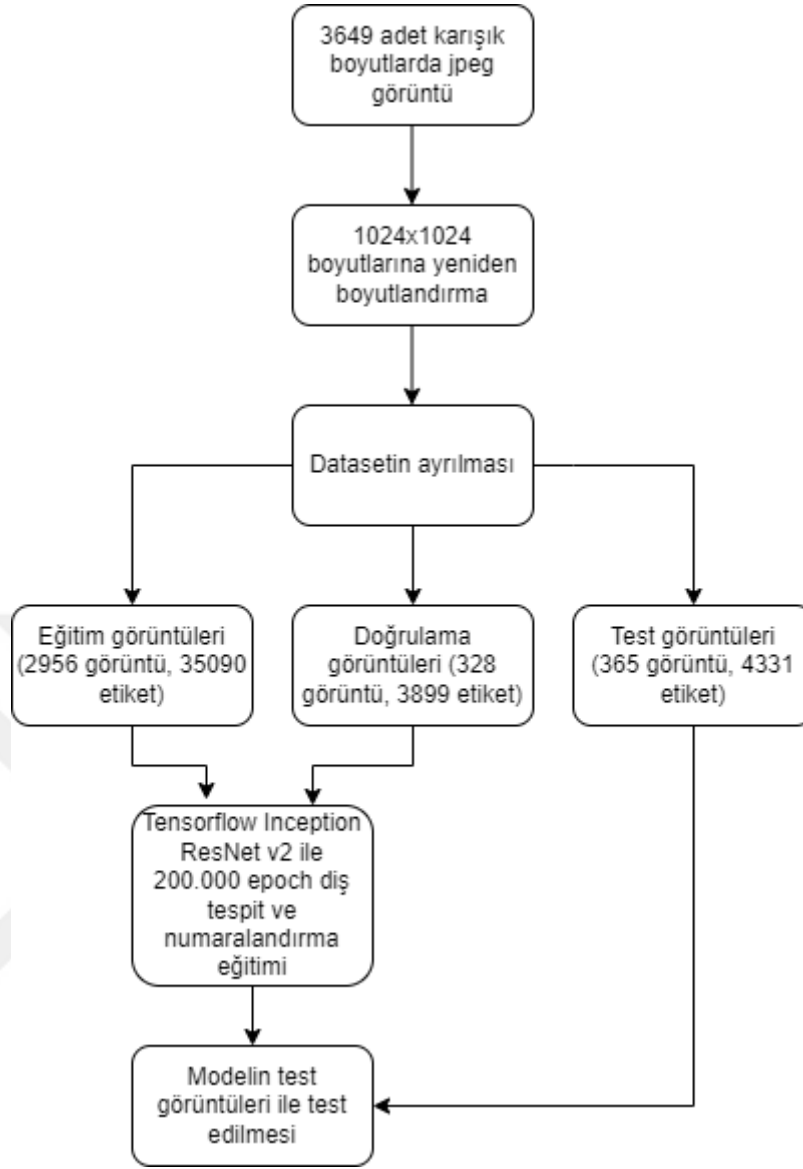
Şekil 3.8. AI algoritmalarının diş tespiti için oluşturduğu tahmini görüntüler (TP, gerçek pozitif)



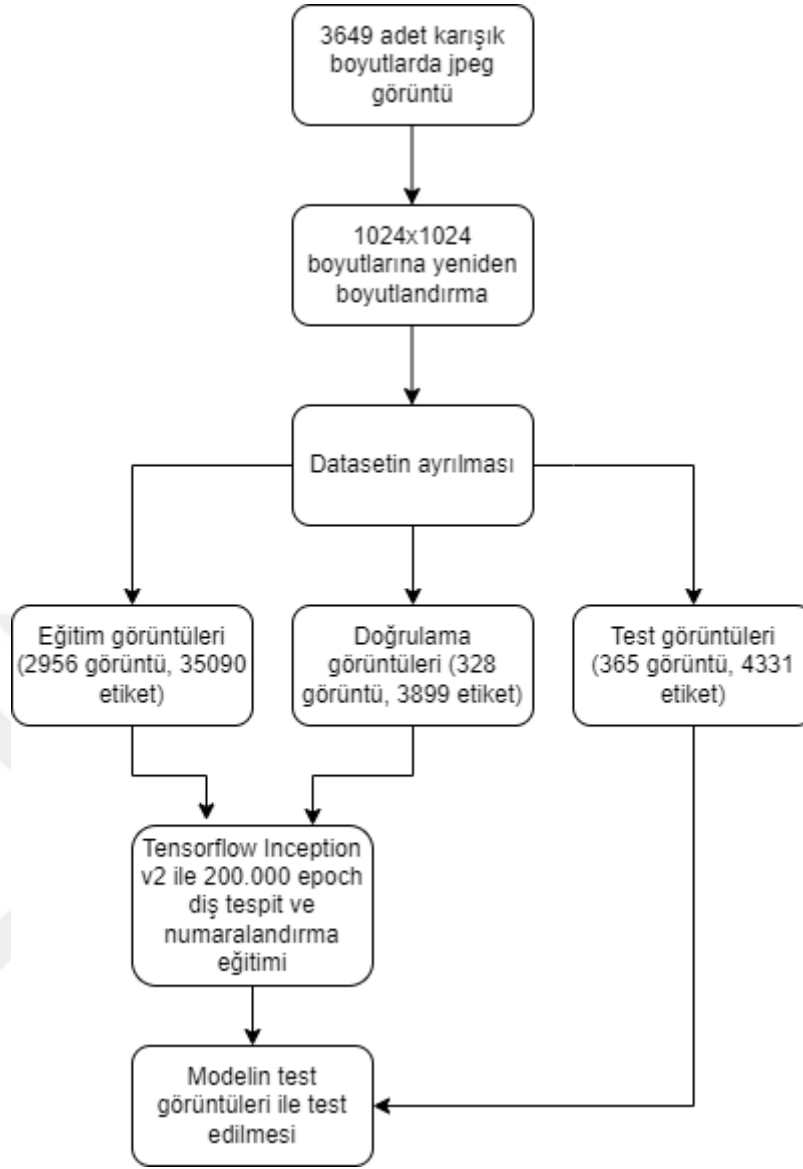
Şekil 3.9. AI algoritmalarının diş tespiti için oluşturduğu tahmini görüntüler (a: FN (yanlış negatif), b: FP (yanlış pozitif))

Diş Tespit ve Numaralandırma Eğitimi

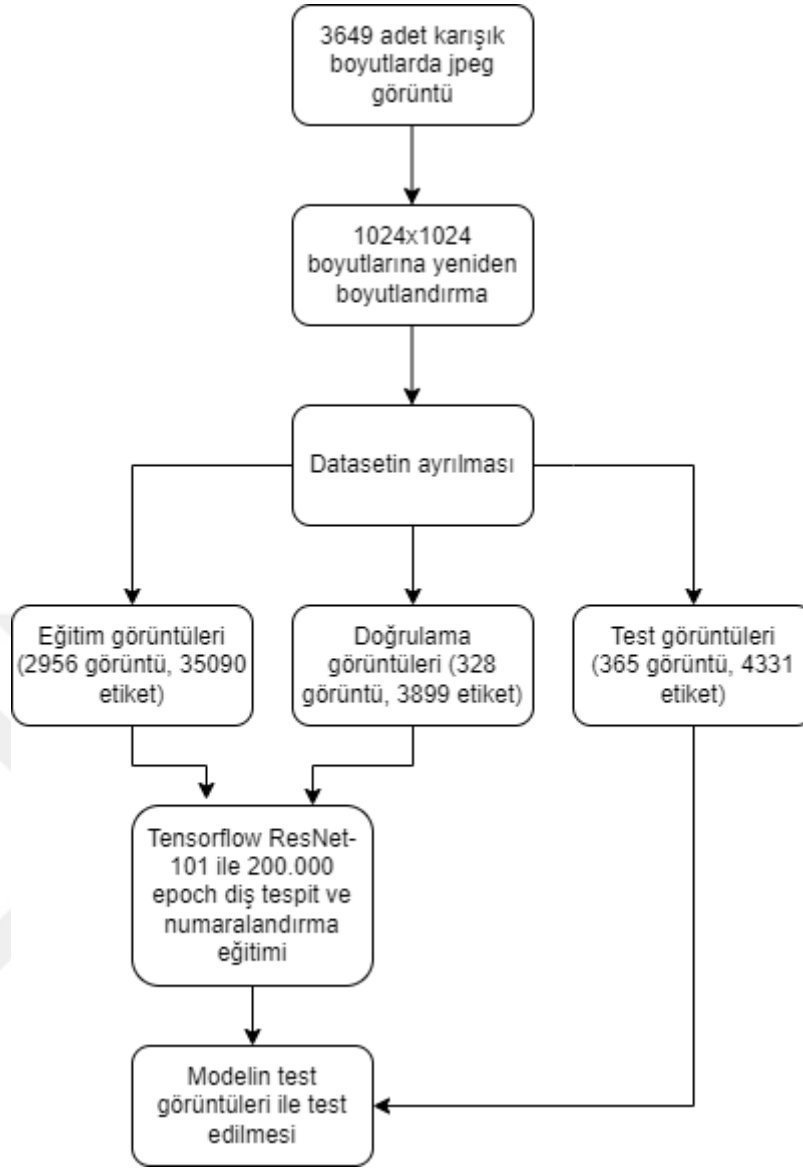
Aksiyel kesit çerçeveler üzerinde 32 farklı dişin etiklendiği eğitim veri seti 2956 adet görüntüden oluşmaktadır. Eğitim grubundaki 2956 aksiyel görüntü üzerinde 35090 diş etiklendi. Modellerin eğitimi 200.000 epoch (eğitim tur sayısı) yapılarak gerçekleştirildi (Şekil 3.10,3.11.,3.12.). Inception ResNet v2, Res-Net-101 ve Inception v2 modellerinin öğrenme hızları (learning rate) ise sırasıyla; 0.0003, 0.0003 ve 0.0002 değerlerindedir. Eğitilen modellerin diş tespit ve numaralandırmada oluşturduğu tahmini görüntüler (Şekil 3.13.,3.14.,3.15.).




Şekil 3.10. Inception ResNet v2 mimarisi ile gerçekleştirilen dış tespit ve numaralandırma modelinin gelişim aşamalarının diyagramı




Şekil 3.11. Inception v2 mimarisi ile gerçekleştirilen dış tespit ve numaralandırma modelinin gelişim aşamalarının diyagramı




Şekil 3.12. ResNet-101 mimarisi ile gerçekleştirilen dış tespit ve numaralandırma modelinin gelişim aşamalarının diyagramı



Şekil 3.12. AI algoritmalarının alt ve üst çenede dişlerin tespitinde ve numaralandırmada oluşturduğu tahmini görüntüler (TP, gerçek pozitif)



Şekil 3.13. AI algoritmalarının diş tespitinde ve numaralandırmada oluşturduğu tahmini görüntüler (TP, gerçek pozitif)



Şekil 3.14. AI algoritmalarının diş tespit ve numaralandırmada oluşturduğu tahmini görüntüler (a: FN (yanlış negatif), b: FP (yanlış pozitif))

3.7. İstatiksel Analiz

Model performanslarını değerlendirmek için karmaşıklık matrisi kullanıldı. Bu matriste modelin performansını değerlendirmek için gerçekleşen işlem için tahminler ve gerçek değerler karşılaştırılır.¹⁵⁰

Karmaşıklık matrisle birlikte Alıcı işlem karakteristiği (Receiver Operating Characteristic Curve-ROC) eğrileri oluşturuldu ve ROC eğrisinin altında kalan alan (Area

Under Curve-AUC) hesaplandı. Böylece üç farklı DL modelinin dış tespit ve numaralandırmadaki performans kıyaslaması yapıldı.

3.7.1. Karmaşıklık Matris Hesaplama Prosedürü

Karmaşıklık matrisi, bir sınıflandırma sistemi tarafından yapılan gerçek ve tahmin edilen sınıflandırmalar hakkında bilgi içerir. Bu tür sistemlerin performansı genellikle matristeki veriler kullanılarak değerlendirilir.¹⁵¹

Modellerin dış tespitindeki başarısını değerlendirmek için kullanılan matrisler aşağıdaki gibidir:

Gerçek pozitif (TP): Dışler doğru tespit edildi.

Yanlış pozitif (FP): Dışler yanlış tespit edildi.

Yanlış negatif (FN): Dışler tespit edilemedi.

Modellerin dış tespiti ve numaralandırmadaki başarısını değerlendirmek için kullanılan matrisler aşağıdaki gibidir:

Gerçek pozitif (TP): dışler doğru olarak tespit edildi ve numaralandırıldı.

Yanlış pozitif (FP): dışler doğru olarak tespit edildi ancak yanlış numaralandırıldı.

Yanlış negatif (FN): dışler tespit edilemedi ve numaralandırılmadı.

3.8. Performans Değerlendirmesi

Duyarlılık (sensitivity-recall): Doğru olan pozitif ve negatif değerlerin ne ölçüde pozitif olduğunu gösterir.⁷⁸

Kesinlik (precision): Pozitif olarak tahmin edilen verilerden ne kadarının doğru tahmin edildiğini gösterir.⁷⁸

F1 skoru: Kesinlik ve duyarlılık veri sonuçlarının harmonik ortalamasıdır. F1 skoru, temel gerçek ile tahmin sonucu arasında örtüşen piksellerin kapsamını etkili bir şekilde yorumlayabilen, segmentasyon değerlendirme metriğidir. Duyarlılık ve kesinlik ölçümlerinin ön hesaplamaları Tablo 3.2.'de gösterilmiştir.⁷⁸ Duyarlılık, kesinlik ve F1 skoru hesaplamaları Tablo 3.3'te gösterilmiştir.

Tablo 3.2. 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 3.3. TP, FP ve FN sayısal değerleri ile hassasiyet, kesinlik ve F1 skoru hesaplama formülleri

Duyarlılık	$TP / (TP + FN)$
Kesinlik	$TP / (TP + FP)$
F1 skoru	$2TP / (2TP + FP + FN)$

Birleşim üzerinden ortalama kesişme: Birleşim üzerinden ortalama kesişim (IoU), doğru pozitifler, yanlış pozitifler ve yanlış negatifler kullanan Pascal VOC 2012'de uygulanan standart bir değerlendirme yöntemidir. IoU metriği, önerilen yöntemin sonucu ile dış tespitindeki kesin referans alanı (nesnelere ait koordinatlar (ground truth)) arasındaki örtüşen bölgeyi gösterir.⁷⁸ Bu alan %50'den büyükse TP (gerçek pozitif), küçükse FP (yanlış pozitif) olarak kabul edilmiştir. IoU'yu hesaplamak için aşağıdaki denklem kullanılır:

$$\text{IoU: } TP / (TP + FN + FP)$$

3.9. Alıcı İşlem Karakteristiđi (AİK-ROC)

ROC, tanısal doğruluđu deđerlendirmek için kullanılan grafiksel bir yöntemdir. Bu grafiđin y ekseninde duyarlılık, x ekseninde özgünlük oranları yer almaktadır. ROC eğrisi altında kalan alanın mümkün olduğunca bire yakın bir deđerde olması beklenir. Bu grafik gerçek pozitifler ve yanlış negatifler arasındaki ilişkiyi gösterir.^{152, 153}

ROC eğrisi çeşitli testlerin etkinliklerinin, farklı tanı tekniklerinin kıyaslanmasını, uygun pozitiflik eşiđinin belirlenmesini sağlar.¹⁵⁴

ROC eğrisinin altında kalan alan (Area Under Curve-AUC) ne kadar büyükse tahminlerin o kadar iyi olduğunu gösterir.¹⁵⁵

4. BULGULAR

Çalışmamızda, dış tespit ve numaralandırma için üç farklı derin öğrenme modelinin, KIBT görüntülerinden elde edilen aksiyel kesitler üzerinde dış tespit ve numaralandırmadaki başarıları araştırılmıştır. Her bir model için karmaşıklık matris kullanılarak performansları değerlendirilmiştir.

Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespiti için TP, FP ve FN değerleri tablo 4.1.'de gösterilmiştir. Inception v2 için TP, FP ve FN değerleri sırasıyla; 4184, 301 ve 153 şeklindedir. ResNet-101 için TP, FP ve FN değerleri sırasıyla; 4074, 167 ve 258 şeklindedir. Inception ResNet v2 için TP, FP ve FN değerleri sırasıyla; 4105, 162 ve 226 şeklindedir. Bu değerlerden hesaplanan duyarlılık, kesinlik ve F1 skorları Tablo 4.2.'de gösterilmiştir. Inception v2 mimarisi için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.9647, 0.9328 ve 0.9485 şeklindedir. Inception ResNet v2 mimarisi için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.9478, 0.9620 ve 0.9548 şeklindedir. ResNet-101 mimarisi için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.9404, 0.9606 ve 0.9504 şeklindedir.

Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespit ve numaralandırma için TP, FP VE FN değerleri Tablo 4.3.'te gösterilmiştir. Inception v2 için TP, FP ve FN değerleri sırasıyla; 4048, 293 ve 240 şeklindedir. ResNet-101 için TP, FP ve FN değerleri sırasıyla; 4045, 267 ve 235 şeklindedir. Inception ResNet v2 için TP, FP ve FN değerleri sırasıyla; 4049, 183 ve 241 şeklindedir. Bu değerlerden hesaplanan duyarlılık, kesinlik ve F1 skorları Tablo 4.4.'te gösterilmiştir. Inception v2 mimarisi için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.9440, 0.9325 ve 0.9382 şeklindedir. Inception ResNet v2 mimarisi için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla

0.9438, 0.9567 ve 0.9502 şeklindedir. ResNet-101 mimarisi için duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.9450, 0.9380 ve 0.9415 şeklindedir.

Tablo 4.1. Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespiti için TP, FP ve FN değerleri

	Inception v2	Inception ResNet v2	ResNet-101
TP (gerçek pozitif)	4184	4105	4074
FP (yanlış pozitif)	301	162	167
FN (yanlış negatif)	153	226	258

Tablo 4.2. Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespiti için duyarlılık, kesinlik ve F1 skoru performans ölçüm değerleri

Ölçü	Inception v2	Inception ResNet v2	ResNet-101	Formül
Duyarlılık	0.9647	0.9478	0.9404	$TP / (TP + FN)$
Kesinlik	0.9328	0.9620	0.9606	$TP / (TP + FP)$
F1 skoru	0.9485	0.9548	0.9504	$2TP / (2TP + FP + FN)$

Tablo 4.3. Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespit ve numaralandırma için TP, FP ve FN değerleri

	Inception v2	Inception ResNet v2	ResNet-101
TP (gerçek pozitif)	4048	4049	4045
FP (yanlış pozitif)	293	183	267
FN (yanlış negatif)	240	241	235

Tablo 4.4. Inception v2, Inception ResNet v2 ve ResNet-101 modellerinin dış tespit ve numaralandırma için duyarlılık, kesinlik ve F1 skoru performans ölçüm değerleri

Ölçü	Inception v2	Inception ResNet v2	ResNet-101	Formül
Duyarlılık	0.9440	0.9438	0.9450	$TP / (TP + FN)$
Kesinlik	0.9325	0.9567	0.9380	$TP / (TP + FP)$
F1 skoru	0.9382	0.9502	0.9415	$2TP / (2TP + FP + FN)$


4.1. ROC (Receiver Operating Characteristic Curve) Eğrisi Grafikleri ve AUC (Area Under Curve)

Performans değerlendirme ölçütü olan ROC eğrisi ve AUC değerleri hesaplanarak modellerin dış tespit ve numaralandırmada gösterdikleri performansların karşılaştırılması yapılmıştır. ROC eğrisi doğru pozitif oranının (TPR), yanlış pozitif oranına (FPR) bölümü ile hesaplanan bir sınıflandırma başarısı ölçütüdür. TPR ve FPR değerlerinin formülasyonları Şekil 4.1.'te gösterilmiştir.¹⁵⁶ ROC eğrisinde amaç sol üst köşede, (0,1) noktasında olmaktır. Bu noktada FPR değeri sıfırdır, yani FP (yanlış pozitif) değeri sıfırdır. ROC eğrisi sol üst köşeye yaklaştıkça testin genel doğruluğu artar.^{157, 158}


$$\text{TPR: } \frac{TP}{TP+FN} \quad \text{FPR: } \frac{FP}{FP+TN}$$

Şekil 4.1. TPR ve FPR değerlerinin formülleri¹⁵⁶


Inception ResNet v2, Inception v2 ve ResNet-101 mimarilerinin dış tespiti için ROC eğrileri aşağıdaki şekillerde gösterilmiştir (Şekil 4.2., 4.3., 4.4.).



Şekil 4.2. Inception ResNet v2 mimarisine ait dış tespit için ROC eğrisi



Şekil 4.3. Inception v2 mimarisine ait dış tespit için ROC eğrisi




Şekil 4.4. ResNet-101 mimarisine ait dış tespit için ROC eğrisi

ROC eğrileri değerlendirildiğinde üç modelin de TPR oranlarının 1'e yakın değerlerde (sol üst köşeye yakın) olduğu tespit edilmiştir. Inception ResNet v2, Inception v2 ve ResNet-101 mimarileri için dış tespitinde AUC değerleri ise sırasıyla; 0.9511, 0.9571 ve 0.9498 olarak elde edilmiştir (Tablo 4.5). Sonuçlar incelendiğinde dış tespitinde en yüksek AUC değerine sahip modelin Inception v2 olduğu tespit edilmiştir.


Tablo 4.5. Çalışmada eğitilen modellerin dış tespiti için AUC değerleri

	Inception ResNet v2	Inception v2	ResNet-101
AUC	0.9511	0.9571	0.9498


Inception ResNet v2, Inception v2 ve ResNet-101 mimarilerinin dış tespit ve numaralandırma için ROC eğrileri aşağıdaki şekillerde gösterilmiştir (Şekil 4.5., 4.6., 4.7.).



Şekil 4.5. Inception ResNet v2 mimarisine ait dış tespit ve numaralandırmadaki ROC eğrisi



Şekil 4.6. Inception v2 mimarisine ait dış tespit ve numaralandırmadaki ROC eğrisi



Şekil 4.7. ResNet-101 mimarisine ait dış tespit ve numaralandırmadaki ROC eğrisi

ROC eğrileri değerlendirildiğinde üç modelin de TPR oranlarının 1'e yakın değerlerde (sol üst köşeye yakın) olduğu tespit edilmiştir. Inception ResNet v2, Inception v2 ve ResNet-101 mimarileri için dış tespit ve numaralandırmada AUC değerleri ise sırasıyla; 0.9485, 0.9389 ve 0.9493 olarak elde edilmiştir. Modellerin AUC değerleri


karşılaştırıldığında, en başarılı performans gösteren modelin 0.9493 değeriyle ResNet-101 mimarisi olduğu tespit edilmiştir (Tablo 4.6.).

Tablo 4.6. Çalışmada eğitilen modellerin dış tespit ve numaralandırma için AUC değerleri


	Inception ResNet v2	Inception v2	ResNet-101
AUC	0.9485	0.9389	0.9493

4.2. Precision (Kesinlik) -Recall (Hassasiyet) Eğrisi (PR Eğrisi)


Kesinlik-hassasiyet eğrisinin x eksenini ile ROC eğrisinin y eksenini TPR (Recall-Duyarlılık) anlamına gelir. Bu nedenle grafikler benzer şekilde gelişir. Kesinlik-Hassasiyet (PR) eğrisi çok önemli olan pozitif sınıfın performansına odaklanmaktadır. PR eğrisindeki amaç ise sağ üst köşede (1,1) olmaktır. Bu nokta tüm pozitifleri pozitif olarak sınıflandırdığımız anlamına gelir (doğruluk oranı artar).¹⁵⁸ Çalışmamızda kullandığımız Inception ResNet v2, Inception v2 ve ResNet-101 modellerinin hem dış tespit hem de dış tespit ve numaralandırma için oluşturulan PR eğrileri incelendiğinde hepsinin sağ-üst köşeye yakın değerde oldukları görülmüştür (Şekil 4.8., 4.9., 4.10, 4.11, 4.12., 4.13).




Şekil 4.8. Inception ResNet v2 mimarisine ait dış tespiti için Precision-Recall eğrisi




Şekil 4.9. Inception v2 mimarisine ait dış tespiti için Precision-Recall eğrisi




Şekil 4.10. ResNet-101 mimarisine ait dış tespiti için Precision-Recall eğrisi



Şekil 4.11. Inception ResNet v2 mimarisine ait dış tespit ve numaralandırma için Precision-Recall eğrisi



Şekil 4.12. Inception v2 mimarisine ait dış tespit ve numaralandırma için Precision-Recall eğrisi



Şekil 4.13. ResNet-101 mimarisine ait dış tespit ve numaralandırma için Precision-Recall eğrisi

5. TARTIŞMA

AI, gerçekleştirilmesini istediğimiz görevlerin, makine ve teknoloji yardımıyla yerine getirilmesinin genel bir ifadesidir.¹⁵⁹ İnsan bilişsel sürecini taklit ederek aynı sonuca çok daha kısa bir sürede ulaşabilmektedir.¹⁶⁰ Sağlık alanında AI uygulamaları fiziksel ve sanal uygulamalar olmak üzere ikiye ayrılmaktadır. Fiziksel AI uygulamaları karmaşık robotlar ve otomatik robotik kolları ifade etmektedir.¹⁶¹ Sanal uygulamalar ise, klinik karar sürecini destekleyen yazılım tipi uygulamaları temsil etmektedir.¹⁶⁰ Diş hekimliğinde AI uygulamaları çoğunlukla sanaldır. Risk faktörlerini önceliklendirmek, lezyonlar ile normal yapıları ayırt etmek, ileriye dönük sonuçları simüle etmek ve değerlendirmek için AI algoritmalarından faydalanılmaktadır.¹⁶⁰ Çalışmamızda KIBT görüntülerinde dişlerin tespit ve numaralandırma için geliştirilen DL tabanlı AI modellerinin başarıları değerlendirilmiştir.

AI diş hekimliğinde diş çürüklerinin derinliğinin değerlendirilmesi¹⁶², apikal lezyon teşhisi^{75, 163}, dental arkların sınıflandırılması¹⁶⁴, diş segmentasyonu⁷⁸, TME osteoartriti¹⁶⁵ ve panoramik radyografilerden osteoporoz tespiti¹⁶⁶, ortodontik tedavi öncesi diş çekim ihtiyacının değerlendirilmesi⁸⁶ gibi birçok alanda kullanılmıştır.

AI ile diş hekimliği alanında özellikle maksillofasiyal radyoloji alanında çalışmalar yapılmıştır.¹⁶⁷ Maksillofasial radyoloji, hastaya teşhis konulmasından yapılacak tedavinin planlamasına kadar olan tüm aşamalarda diş hekimine birçok bilgi sağlar. Diş hekimliğinde görüntüleme; periapikal, bite-wing gibi intraoral yöntemler ve panoramik gibi ekstraoral görüntüleme teknikleriyle yapılabilmektedir.^{168, 169} AI ve CNN diş hekimliği alanında 2B ve 3B radyografiler üzerinde birçok çalışmada kullanılmıştır.¹⁷⁰

AI ile panoramik radyografi görüntülerinde; diş tespit ve segmentasyonu^{76, 78}, molar dişlerde ekstra kök varlığı tespiti¹⁷¹, vertikal kök kırıklarının tespiti¹⁷², gömülü

süpernumerer diş varlığı tespiti¹⁷³, apikal lezyon tespiti¹⁶³, osteoporoz tespiti⁸⁵, üçüncü molar dişlerin çekim zorluğunun değerlendirilmesi⁹⁹, periodontal kemik kaybının tespiti^{71, 174}, adli diş hekimliği¹²⁶, implant marka ve tedavi aşaması tespiti¹⁷⁵, odontojenik kist ve tümör tespiti^{176, 177}, mandibula fraktür tespiti¹⁷⁸, dudak-damak yarığı¹⁷⁹ alanlarında çalışmalar yapılmıştır.

Periapikal radyografi görüntüleri üzerinde AI; diş tespit ve segmentasyonu^{73, 180}, çürük tespiti¹¹¹, taşkın restorasyon tespiti¹⁸¹, periodontal hastalıkla ilişkili durumu kritik dişlerin belirlenmesi¹⁸², implant tespiti¹¹⁷, anatomik landmark tespiti¹⁸³, dental restorasyon sınıflaması¹⁸⁴ için kullanılmıştır.

Bite-wing radyografi görüntüleri üzerinde ise AI; diş tespit ve segmentasyonu¹⁸⁵, çürük tespiti¹⁰⁸, taşkın restorasyonların tespiti¹⁸¹, anatomik landmark tespiti¹⁸³, dental restorasyon sınıflaması¹⁸⁴ alanlarında uygulanmıştır.

Literatürde AI ile KIBT görüntüleri üzerinde yapılmış birçok çalışma bulunmaktadır. KIBT 3B bir görüntüleme yöntemi olup, panoramik ve intraoral radyografilerde ortaya çıkan distorsiyon ve magnifikasyon gibi istenmeyen özellikleri yoktur. Kraniofasial bölgeyi 3 farklı düzlemde (aksiyel, sagittal ve koronal) incelemeyi sağlayarak hekimlere detaylı bilgi sunar.¹³⁶ Çalışmamızda diş tespit ve numaralandırma için KIBT görüntüleri kullanılmıştır.

AI KIBT görüntülerinde; diş tespit ve segmentasyonunda¹⁸⁶, diş köklerinin segmentasyonunda¹⁸⁷, periapikal patolojilerin tespitinde⁷⁵, gömülü mandibular üçüncü molarların değerlendirilmesinde¹⁸⁸, ortognatik cerrahide⁹¹, implantolojide¹¹⁹, farengeal hava yolu tespit ve segmentasyonunda¹⁸⁹ kullanılmıştır.

Literatürde, DL tabanlı AI modelleri ile diş tespit ve numaralandırmanın yapıldığı birçok çalışma bulunmaktadır. Tuzoff ve ark. panoramik radyografiler üzerinde CNN' dayalı bir model ile diş tespit ve numaralandırma gerçekleştirmişlerdir. Dişler FDI

sistemine göre numaralandırılmıştır ve çalışmada 1352 adet panoramik radyografi kullanılmıştır. Faster R-CNN (Region-Based Convolutional Neural Network) mimarisine dayalı model %99 başarı göstermiştir.⁷⁴ Lee ve ark.⁷⁸ ise 50 adet panoramik radyografi üzerinde Mask R-CNN DL tekniği ile diş segmentasyonu gerçekleştirmişlerdir. Yöntemin %85 oranında doğru numaralandırma yaptığını ve adli diş hekimliğinde kimlik tespitinde yararlı olabileceğini belirtmişlerdir.⁷⁸ Bir başka çalışmada ise 153 adet panoramik radyografi veri seti kullanılarak diş tespiti ve segmentasyonu için bir AI modeli geliştirilmiştir. Resnet-101 ile birlikte deeplab-v3 mimarisine sahip olan modelde Pytorch framework ile 100 epoch eğitilen çalışmada sonuç olarak sistemin hassasiyet oranının %98,9 olduğu belirtilmiştir.¹⁹⁰ Bir diğer çalışmada ise, 550 adet panoramik radyografi üzerinde maksiller kesici bölgedeki gömülü süpernümerer diş varlığının tespit ve sınıflandırması için üç farklı DL modeli (DetectNet, AlexNet, VGG-16) kıyaslamışlardır. AlexNet ve VGG-16 mimarileri sadece nesne sınıflandırma fonksiyonuna sahipken çalışmada kullanılan DetectNet mimarisi hem nesne sınıflandırma hem de nesne algılama fonksiyonlarını yerine getirebilmektedir. AlexNet ve VGG-16 mimarileri ile 200, DetectNet mimarisi ile 1000 epoch eğitimi gerçekleştirdiler. Sonuç olarak en yüksek tanısal etkinlik gösteren AI modelinin DetectNet olduğu tespit edilmiştir. DetectNet modelinin maksiller kesici bölgedeki diş varlığını tahmin etmedeki kesinlik oranının 1.0 olduğu belirtilmiştir.¹⁷³ Çalışmamızda diş tespit ve numaralandırma için Inception v2, Inception ResNet v2 ve ResNet-101 mimarileri kullanılmış ve performansları kıyaslanmıştır. Inception Resnet 2 mimarisi ile 0.9502 gibi yüksek bir F1 skoru elde edilmiştir.

Muramutsu ve ark. dörtlü çapraz doğrulama yöntemi kullanarak nesne algılama için bir DL modelinin eğitimini gerçekleştirmişlerdir. Yüz adet panoramik radyografi üzerinde dişleri dört farklı grupta (keserler, kaninler, premolarlar, molarlar) ve kısmen

restore edilmiş, tamamen restore edilmiş, non-metal restore edilenler olarak da üç farklı grupta sınıflandırmışlardır. Diş tespiti için GoogleNet tabanlı bir CNN ağı mimarisi olan DetecNet, dişleri sınıflandırmak için ise ResNet50 mimarisini kullanmışlardır. Eğitilen model diş tespitinde %96.4'lük hassasiyet, diş tiplerini sınıflandırmada ise %93.2 oranında doğruluk göstermiştir.¹⁹¹ Bu çalışmada ise, dişler 32 farklı numara ile sınıflandırılmış olup restorasyon varlığına göre ayrılmamıştır. Çalışmamızda kullanılan ResNet mimarilerinin başka bir versiyonu olan ResNet-101'in F1 skoru 0.9415 ve AUC değeri 0.9493 olup oldukça yüksek başarı göstermiştir.

Bilgir ve ark. 2482 adet panoramik radyografi üzerinde Faster R-CNN Inception v2 mimarisine dayalı bir AI modeli ile FDI sistemine göre dişlerin tespiti ve numaralandırmasını gerçekleştirmişlerdir. 200.00 epoch eğitilen modelde dişlerin tespit ve numaralandırmasında %95.5 oranında hassasiyet elde etmişlerdir.¹⁹² Kılıc ve ark.⁷⁶ yaptıkları bir çalışmada çocuk hastaların panoramik radyografi görüntüleri üzerinde süt dişi tespit ve numaralandırması için derin öğrenme yaklaşımı temelli otomatik bir yöntem geliştirmişlerdir. Çalışmalarında 402 adet panoramik radyografi üzerinde Faster R-CNN Inception v2 (COCO) modelini kullanan bir AI algoritması geliştirmişlerdir. Sistemin performansı karmaşıklık matris kullanılarak değerlendirilmiştir. Sonuç olarak geliştirilen AI modelinin duyarlılık, kesinlik ve F1 skoru değerlerinin sırasıyla 0.9804, 0.9571 ve 0.9686 olarak tespit edildiğini ve sistemin yüksek oranda başarı gösterdiğini bildirmişlerdir. Çalışmamızda diş tespit ve numaralandırma KIBT görüntüleri üzerinde yapılmıştır. Çalışmamızda modellerin performansının değerlendirilmesinde karmaşıklık matris kullanılmıştır. Karşılaştırdığımız mimarilerden olan Inception v2 mimarisinin diş tespit ve numaralandırmadaki duyarlılık, kesinlik ve F1 skorları ise 9440, 9325 ve 9382 şeklinde elde edilmiştir.

Diğer bir çalışmada Chen ve ark. Faster R-CNN Inception ResNet v2 modeli ile 1250 adet periapikal radyografi üzerinde FDI sistemine göre diş tespit ve numaralandırması gerçekleştirmişlerdir. Diş tespitinde %90'ın üzerinde kesinlik değeri elde etmişlerdir.⁷³ Çalışmamızın sonuçları incelendiğinde F1 skoru en yüksek elde edilen mimari hibrit bir model olan Inception ResNet v2 olmuştur, yüksek başarı göstermiştir.

Cansu ve ark. 1686 adet periapikal radyografiyi veri seti olarak kullandıkları bir çalışmada ön işleme için GoogLeNet Inception v3 modeli kullanarak, FDI sistemine göre diş tespit ve numaralandırma gerçekleştirmişlerdir. Diş tespiti ve numaralandırma için Faster R-CNN yöntemi uygulamışlardır. Geliştirilen modeldeki algoritma çene sınıflandırma modeli, bölge algılama modeli ve final model olmak üzere üç kısımdan oluşuyordu. Çene sınıflaması yapıldıktan sonra dental nesne algılama modeli ile 500.000 epoch eğitildi. Dişler tespit edildikten sonra algoritma FDI sistemine göre tek tek diş numarasını belirlemek için eğitildi. Sonuç olarak modelin F1 skoru, kesinlik ve hassasiyet değerlerini sırasıyla 0.8720, 0.7812, ve 0.9867 olarak elde etmişlerdir.¹⁸⁰ Çalışmamızda KIBT görüntüleri üzerinde çenelerin sınıflandırması yapılmadan görüntüler direkt olarak DL algoritmalarına aktarılarak eğitim yapılmıştır.

Kıyaslanan her üç DL modeliyle de %93'ün üzerinde AUC değeri elde edilmiştir. Çalışmamızın sonuçları DL algoritmalarının öğrenme yeteneğinin gücünü göstermektedir.

Yasa ve ark. 1125 adet bite-wing radyografi kullanarak Faster R-CNN Inception v2 (COCO) modeli ile FDI sistemine göre diş tespit ve numaralandırılması gerçekleştirmişlerdir. 200.000 epoch eğitilmiştir. Geliştirilen AI modeli 715 diştten 697'sini doğru olarak tespit edip, numaralandırmıştır. Çalışmanın F1 skoru, kesinlik ve hassasiyet değerleri sırasıyla; 0.9515, 0.9293 ve 0.9748 olarak elde edilmiştir.⁷⁹

Çalışmamızda dişler FDI sistemine göre numaralandırılıp KIBT görüntüleri üzerinde 200.000 epoch eğitilmiştir.

Miki ve ark.⁸⁰ 52 hastanın KIBT verileri üzerinde AlexNet mimarisini kullanarak geliştirdikleri bir AI sistemi ile diş tespit ve segmentasyonunu gerçekleştirmişlerdir. Çalışmalarında aksiyel kesitler üzerinde tek tek dişleri ve dişler dışında kalan alanları içerecek şekilde 2 farklı sınıflandırma yapmak üzere dikdörtgen kutular manuel olarak çizilmiştir. Bu görev için AlexNet mimarisini kullandılar. AlexNet 5 evrişim katmanı, 3 havuz katmanı ve 3 tam bağlantılı katmandan oluşur. Dişleri 7 diş tipine göre sınıflandırdılar (santral, lateral, kanin, birinci premolar, ikinci premolar, birinci molar, ikinci molar). Eğitilen modelin diş tespiti için %77.4'lük, diş tiplerinin sınıflandırması için ise %77.1'lik doğruluk oranı gösterdiğini bildirmişlerdir. Çalışmamızda transfer öğrenme teknikleriyle kullandığımız mimariler diş tespit ve sınıflandırma için eğitilmiştir. Diş segmentasyonu yapılmamıştır.

Buna benzer bir çalışma ortaya koyan Muramutsu ve ark.⁸¹ 84 hastanın KIBT verilerini kullanarak diş tespit ve sınıflandırması yapmışlardır. Veri seti az olduğu için değerlendirmeyi dörtlü çapraz doğrulama yöntemiyle yaptıklarını belirtmişlerdir. KIBT veri seti 21 vakalık 4 set halinde gruplandırılmış ve 3'ü eğitim için, geri kalanlar test için kullanılmıştır. Dişleri 8 diş tipine göre sınıflandırdılar (santral, lateral, kanin, birinci premolar, ikinci premolar, birinci molar, ikinci molar, üçüncü molar). Aksiyel kesitler üzerinde her diş tek tek dikdörtgen kutular çizilerek belirlendi. Çalışmalarında ilişki ağı (Relation Network) kullandılar. Bu ağ Faster R-CNN modelinin modifiye şeklidir. Sistemin diş tespit etme oranı ortalama olarak %99.1, diş tiplerini sınıflandırmadaki doğruluğu %98.3 olarak elde edildi.

Bir görüntü üzerinde nesnenin görüntünün neresinde olduğu ve kapladığı sınırların belirlenmesine nesne tanımlama işlemi denir.³⁸ Nesne tanıma ve tespitinde R-CNN, Fast

R-CNN, Faster R-CNN, Mask R-CNN gibi birçok metod kullanılmaktadır. R-CNN en temel modeldir. Nesnenin resimdeki yerini gösteren 4 değer verir (dikdörtgenin sol üst köşesindeki x ve y koordinatları genişlik uzunluk değerleri).¹⁹³ Nesneye ait bölge önerileri çıkarır ve bu önerilere CNN uygulanır.¹⁹⁴ Fast R-CNN DCNN kullanarak nesne tespitini daha hızlı bir şekilde yapar. R-CNN modelinin hız sorununu çözmek için geliştirilmiştir. R-CNN'den farkı ilk olarak CNN uygulanması sonrasında özellik haritasına göre bölgelerin elde edilmesidir. Her bir görüntü için CNN kullanmak yerine, tek bir kez CNN kullanıp tüm öneriler arasında bu hesaplamanın paylaşımı yapılmaktadır. Böylece eğitim ve test çok daha kısa sürede yapılabilmektedir. Sınıflandırma işlemi Softmax (Entropi) kullanılarak yapılmaktadır.^{195, 196} Softmax katmanında sınıflandırma yapılırken hangi sınıfa daha yakın olduğunun DL ağı ile olasılıksal değeri elde edilir.¹⁹⁷

Faster R-CNN de R-CNN'deki çalışma zamanını azaltmak için geliştirilmiştir. Bölge öneri ağı (RPN, Region Proposal Network) ile Fast R-CNN modellerinin birleşmiş halidir. RPN son konvolüsyon katmanından sonraki katmana eklenmiştir. Nesnenin konumunu giriş verisindeki görüntüyü sınıflandırma aşamasında bir kez kullanarak hesaplar.¹⁹⁸

Mask R-CNN ise bölgesel tabanlı nesne tespit algoritmalarının en gelişmiş modelidir. Diğer yöntemlerden farkı nesnenin olduğu tüm pikselleri tespit ederek her örnek için yüksek kalitede segmentasyon maskesi oluşturur. Nesne tanıma aşamasında yine Faster R-CNN'i kullanır.^{195, 199, 200}

Nesne tanımlama alanındaki en büyük yarışma 2012 yılında gerçekleştirilen ImageNet (Büyük Ölçekli Görsel Tanıma) yarışması olmuştur.⁴² AlexNet, ImageNet yarışmasında adını duyuran ve yarışmayı kazanan 25 katmandan oluşan bir mimaridir. Beş konvolüsyon katmanı, 3 havuzlama katmanı ve 3 tam bağlantılı katmandan oluşan mimari 1000 nesneyi sınıflandırma özelliğine sahiptir.⁴⁹ Evrişim filtreleri 11x11

boyutunda kullanılmaktadır. ImageNet veri tabanında %80 doğruluk elde etmiş bir derin öğrenme mimarisidir.^{42, 52}

GoogleNet yapısında Inception modülleri olan karmaşık bir mimaridir. Yüz kırk dört katmanlı olan bu mimarinin diğer mimarilerden farkı konvolüsyon ve havuzlama katmanlarını üst üste yığmak yerine paralel olarak birbirine bağlı modüller şeklinde kullanır. Böylece sistemin ezberleme olasılığı düşürülür.⁴⁶ Inception modülü ile farklı boyutlarda filtremeler (1x1, 3x3 ve 5x5) yapabilmektedir.⁵² Bu mimarinin ImageNet veri tabanındaki doğruluk oranı %93'tür.⁵² Bu çalışmada performansı değerlendirilen mimarilerden biri GoogleNet Inception mimarilerinin bir versiyonu olan Inception v2'dir.

Inception-Resnet modeli ise hibrit bir modeldir. Inception mimarisinde yer alan Inception modülleri ve ResNet mimarisinin birleştirilmiş halidir. Böylece Inception modülleri, artık (residual) Inception modüllerine dönüştürülmektedir.²⁰¹ Bu çalışmada performansı değerlendirilen diğer bir model ise, Inception ResNet v2'dir.

ResNet mimarisi ise bu mimarilere göre çok daha derin bir yapıdadır. Hata oranının oldukça düşük olması en önemli özelliklerinde biridir. Yüz elli iki katmandan oluşan bu mimari residual bloklardan oluşmaktadır.¹⁴⁵ Residual bloklar (kalıntı) bu mimariyi diğerlerinden ayıran en önemli farktır. Bu bloklar sayesinde ilgili katmanda herhangi bir değer elde edilemese bile, bir önceki katmandan gelen artık değer kullanılır.¹⁴⁵ ResNet mimarileri ve varyasyonları günümüzde en gelişmiş CNN modelleri olarak ifade edilmektedir.²⁰² Çalışmamızda dış tespit ve numaralandırmada kullanılan ve en yüksek AUC değeri elde ettiğimiz mimari ResNet-101'dir. ResNet-101 ve Inception v2 modellerinin eğitimi yaklaşık olarak yarım gün sürmüştür. En yüksek F1 skoru elde ettiğimiz mimari olan Inception ResNet v2'nin eğitimi ise 2 gün sürmüştür. Bunun sebebi olarak iç içe geçmiş 2 farklı mimari ağının (Residual blok ve Inception) birleştirilmesiyle oluşması ve hesaplama yükünün daha fazla olması gösterilebilir.

VggNet 2014 yılında geliştirilen modelin diğer mimarilerden farkı 2x2 ve 3x3 lük filtreler uygulanmasıdır. Bu küçük filtreler sayesinde görüntüden daha iyi özellikler çıkarılmaktadır. En popüler VggNet mimarileri VGG-16 ve VGG-19 modelleridir.^{43, 52} VGG-16, 13 konvolüsyon katmanı, 3 tam bağlı katman, 5 havuzlama, Relu, Dropout ve Softmax katmanları dâhil toplam 41 katmandan oluşmaktadır.⁵² ImageNet veri tabanındaki doğruluk oranı %89'dur. VGG-19, 16 konvolüsyon, 3 tam bağlantılı katmandan oluşmuş olup doğruluk oranı ise %88'dir.^{43, 52} DetectNet mimarisi ise nesnelerin sınıflandırmasını ve sınırlayıcı kutularla çizilmesini sağlayan bir derin öğrenme mimarisidir.²⁰³

Segmentasyon (görüntü bölümlenme) bir görüntü farklı özelliklerin izlendiği anlamlı bölgelere ayırma işlemidir. Her piksel için etiketler çıkartılır ve bu etiketlere dair çıkarımlar yapılır. Bu alanda kullanılan temel DL modeli CNN olmasına karşın, bu modelde yapılan iyileştirmeler sonucunda FCN (Fully Connected Network) modeli elde edilmiştir. FCN modelinde son tam bağlı katman tamamen evrişimli bir katmanla değiştirilmiştir bu sayede model daha akıllı bir piksel tahmininde bulunma yetisi kazanmıştır.^{204, 205} Böylece piksel düzeyinde tahminler yapılmış olur. Medikal görüntülerde segmentasyonda kullanılan bir diğer model ise U-Net mimarisidir. Daralma ve genişleme olmak üzere iki ana bölümden oluşan bu mimari bilgilerin daha derin katmanlara uygulanmasını sağlayarak daha doğru bir segmentasyon yapılmasını sağlar. Daralma bölümünden elde edilen özellikler genişleme bölümüne aktarılır ve bu bölümde görüntü elde edilmiş olur.^{62, 205} DeepLab ise ilk olarak 2015 yılında tasarlanmış bir segmentasyon modelidir. Birçok varyasyonu olmasına karşın segmentasyon alanında en başarılı versiyonu DeepLab v3'tür.⁴⁴ Çalışmamızda dış tipleri nesne tanımlama ile tespit edildi ve numaralandırma yapıldı, segmentasyon maskesi elde edilmedi.

AI sayesinde diş hekimliğinin diğer bir gelişen alanı ise dijital diş hekimliğidir. İntrooral ve yüz tarayıcılar, dental 3B yazıcılar DL tabanlı algoritmalar sayesinde gelişmektedir. Dijital diş hekimliği ve AI algoritmaları sayesinde çenelerin ve kafatasının 3B segmentasyonu yapılabilmektedir.⁸² Medikal görüntülerde özellikle FCN ile 3B hacim oluşturma çalışmalarında başarılı sonuçlar elde edilmiştir.⁶³ Lee ve ark.²⁰⁶ ve Rao ve ark.²⁰⁷ FCN kullanarak KIBT görüntüleri üzerinde dişlerin 3B segmentasyonunu gerçekleştirmişlerdir. Chen ve ark.¹⁸⁶ ise yine 3B FCN kullanarak dişleri segmente etmişlerdir. Chui ve ark.²⁰⁸ ise 3B Mask R-CNN kullanarak dişleri segmente etmişlerdir. Çalışmalarına yirmi yaş dişlerini dâhil etmemişlerdir. Jang ve ark.⁸² 3B Mask R-CNN kullanarak 3B diş segmentasyonu gerçekleştirmişlerdir. Çalışmada diş tiplerini sınıflandırmada %93.35'lik, diş segmentasyonunda ise kesinlik oranını %95.97 olarak elde ettiklerini bildirmişlerdir. Chung ve ark.²⁰⁹ diş tespiti için Faster R-CNN, diş segmentasyonu için ise 3B U-Net mimarisi kullanmışlardır. Elli KIBT verisi kullandıkları çalışmalarında %93'ün üzerinde başarı elde etmişlerdir. Wu ve ark.²¹⁰ da dişlerin segmentasyonu için 3B U-Net kullandıkları çalışmalarında, 20 hastanın KIBT görüntüsünü kullanmışlardır. %99'un üzerinde başarı elde etmişlerdir. Çalışmamızda KIBT DICOM verileri üzerinden elde ettiğimiz aksiyel kesitler üzerinden dişler tespit edilmiş ve numaralandırılmıştır, dişlerin 3B segmentasyonu gerçekleştirilmemiştir.

Çalışmamızda artefaktlı görüntüler, kraniofasiyal sendromu, dudak damak yarığı, kraniofasiyal bölge kemik hastalıkları olan hastalar, protetik restorasyon ve dental implanta sahip hastalar ve diş eksikliği olan, ortognatik cerrahi görmüş hastaların görüntüleri veri setine dahil edilmemiştir. Çalışmamızın dar bir popülasyonda yapılmış olması limitasyonumuzdur.

Çalışmamızda veri setini oluşturan bütün görüntüler aynı KIBT cihazında, aynı parametrelerle çekilen görüntülerden oluşmaktadır. Farklı cihazlar, farklı voksel

boyutlarına sahip görüntüler ve farklı çekim parametreleri uygulanarak elde edilecek görüntülerle yapılacak olan çalışmalar ile daha etkin AI modelleri elde edilebilir. Ayrıca elde edilen AI modellerinin başarısının daha iyi değerlendirilebilmesi için eksternal test veri seti kullanılması önerilmektedir.

Çalışmamızda görüntüler bir Ağız, Diş ve Çene Radyolojisi uzmanı ve bir araştırma görevlisi tarafından değerlendirilmiştir. Hem gözlemci sayısı artırılarak hem de farklı branşlardan farklı deneyimlere sahip diş hekimleri seçilerek başarı kıyaslaması yapılabilir.



6. SONUÇ VE ÖNERİLER

Geliştirdiğimiz AI algoritmalarının KIBT görüntüleri üzerindeki dış tespit ve numaralandırmadaki sonuçları umut vericidir. Çalışmada eğitilen Inception v2, ResNet-101 ve Inception ResNet v2 AI modellerinin tümünde F1 ve AUC değerleri %93'ün üzerinde elde edilmiştir.

Elde edilen sonuçlar AI destekli sistemlerin, klinik rutinde hekimlere zaman kazandıracak bir karar destek mekanizması işlevi görme potansiyeline sahip olabileceğini göstermektedir.

Veri setine dâhil etmediğimiz hasta grupları çalışmamızın limitasyonlarından biridir. İlerleyen dönemlerde yapılacak olan çalışmalarda çalışmaya dâhil etme kriterleri genişletilerek daha geniş bir popülasyon üzerinde çalışılarak, klinik uygulama açısından daha yararlı AI algoritmaları elde edilmesi sağlanabilir.

Gelecek çalışmalarda farklı cihazlardan elde edilen, farklı çözünürlüklere sahip ve farklı çekim parametreleri ile elde edilmiş görüntülerin kullanılması klinik kullanım açısından daha geçerli AI modellerinin elde edilmesini sağlayacaktır. AI modellerinin başarısının daha iyi tespit edilebilmesi için farklı uzmanlığa ve deneyimlere sahip dış hekimleri ile başarılarının karşılaştırıldığı çalışmalar yapılmalıdır.

KAYNAKLAR

1. Allen Jr B, Seltzer SE, Langlotz CP, Dreyer KP, Summers RM, Petrick N, Marinac-Dabic D, Cruz M, Alkasab TK, Hanisch RJ. A road map for translational research on artificial intelligence in medical imaging: from the 2018 National Institutes of Health/RSNA/ACR/The Academy Workshop. *J Am Coll Radiol*. 2019;16(9):1179-1189.
2. Sen D, Chakrabarti R, Chatterjee S, Grewal D, Manrai K. Artificial intelligence and the radiologist: the future in the Armed Forces Medical Services. *BMJ Mil Health*. 2020;166(4):254-256.
3. Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *Eur Radiol Exp*. 2018;2(1):1-10.
4. Neri E, de Souza N, Brady A, Bayarri A, Becker C, Coppola F, Visser J. What the radiologist should know about artificial intelligence-an ESR white paper. *Insights Imaging*. 2019; 10:1-8.
5. Pirim H. Yapay zeka. *J Yas Uni*. 2006;1(1):81-93.
6. Uzun T. Yapay Zeka Ve Sağlık Uygulamaları. *J Bus Gov*. 2020;3(1):80-92.
7. Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi* 2018;6(2):25-36.
8. Turing IBA. Computing machinery and intelligence-AM Turing Mind. 1950;59(236):433.
9. Arslan K. Eğitimde Yapay Zeka ve Uygulamaları. *BAEBD*. 2020;11(1):71-88.
10. Moor J. The Dartmouth College artificial intelligence conference: The next fifty years. *AI MAG*. 2006;27(4):87-87.

11. Bellman R. An introduction to artificial intelligence: can computers think? Thomson Course Technology; 1978.
12. 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.* 2020;16(1):508-522.
13. Samuel AL. Some studies in machine learning using the game of checkers. II—Recent progress. *IBM J Res Dev* 1967;11(6):601-617.
14. Nichols JA, Chan HWH, Baker MA. Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophys Rev.* 2019;11(1):111-118.
15. Fausett L. Fundamentals of Neural Networks Architectures, Algorithms, and Applications. Prentice-Hall. Englewood Cliffs 1994; 156-217
16. Benko A, Lányi CS. History of artificial intelligence. *Encyclopedia of Information Science and Technology, Second Edition*, IGI Global, 2009: 1759-1762.
17. Maltarollo VG, Honório KM, da Silva ABF. Applications of artificial neural networks in chemical problems. *Artificial neural networks-architectures and applications* 2013;203-223.
18. 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.
19. Öztemel E. Yapay sinir ağları. Papatya Yayıncılık, İstanbul 2003. p. 29-45.
20. Lee J-G, Jun S, Cho Y-W, Lee H, Kim GB, Seo JB, Kim N. Deep learning in medical imaging: general overview. *Korean J Radiol.* 2017;18(4):570.
21. Burt JR, Torosdagli N, Khosravan N, RaviPrakash H, Mortazi A, Tissavirasingham F, Hussein S, Bagci U. Deep learning beyond cats and dogs: recent advances in

- diagnosing breast cancer with deep neural networks. Br J Radiol. 2018;91(1089):20170545.
22. Hwang J-J, Jung Y-H, Cho B-H, Heo M-S. An overview of deep learning in the field of dentistry. Imaging Sci Dent. 2019;49(1):1-7
 23. Ağyar Z. Yapay sinir ağlarının kullanım alanları ve bir uygulama. Mühendis ve Makine 2015;56(662):22-23.
 24. Kabalcı E. Yapay Sinir Ağları. Ders Notları <https://ekblc.files.wordpress.com/2013/09/ysa.pdf> 2014.
 25. Kaynar O, Görmez Y, Yıldız M, Albayrak A. Makine öğrenmesi yöntemleri ile Duygu Analizi, IDAP. 2016; 17-18.
 26. Serhatlıoğlu S, Hardalaç F. Yapay Zeka Teknikleri ve Radyolojiye Uygulanması. Fırat Tıp Dergisi 2009;14(1):1-6.
 27. Efe MÖ, Kaynak O. Yapay sinir ağları ve uygulamaları. Boğaziçi Üniversitesi; 2004.p. 1-1.
 28. Asilkan Ö, Irmak S. İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. SDÜ İİB Dergisi 2009;14(2):375-391.
 29. Neri E, de Souza N, Brady A, Bayarri Aa, Becker Cd, Coppola F, Visser J. What the radiologist should know about artificial intelligence—an ESR white paper. Insights Imaging. 2019;101-108.
 30. Suzuki K. Overview of deep learning in medical imaging. Radiol Phys Technol. 2017;10(3):257-273.
 31. Baydilli Y. Derin Öğrenme Yöntemleri İle Periferik Yayma Görüntülerinin Analizi Ve Sınıflandırılması. 2020.
 32. Şeker A, Diri B, Balık HH. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. GMBD. 2017;3(3):47-64.

33. Brothie P. Machine learning in radiology. *J Med Imaging Radiat Oncol.* 2019;63(1):25-26.
34. Murphy KP. *Machine learning: a probabilistic perspective.* MIT press; 2012. p. 1-16.
35. Koushik J. Understanding convolutional neural networks. arXiv preprint arXiv: 2016:1605.09081.
36. Liu YH. Feature extraction and image recognition with convolutional neural networks. *J Phys Conf Ser.* 2018; 062032.
37. Kim P. *Matlab deep learning. With machine learning, neural networks and artificial intelligence* 2017;13021.
38. Özkan İ, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *GBAD.* 2017;6(3):85-104.
39. Gülcü A, Zeki K. Konvolüsyonel sinir ağlarında hiper-parametre optimizasyonu yöntemlerinin incelenmesi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji* 2019;7(2):503-522.
40. ZahediNasab R, Mohseni H. Neuroevolutionary based convolutional neural network with adaptive activation functions. *Neurocomputing* 2020;(381):306-313.
41. Tur AO. Derin öğrenme yöntemleri kullanarak etkin ayrık işaret dili tanıma sistemi geliştirme. *Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı. Yüksek Lisans Tezi, Ankara: Ankara Üniversitesi, 2021.*
42. Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Adv Neural Inf Process Syst.* 2012;25:1097-1105.
43. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv: 2014;1409.1556.

44. Chen LC, 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.* 2017;40(4):834-848.
45. Zeiler MD, Fergus R. Visualizing and understanding convolutional networks, *ECCV*, Springer, Cham, 2014. p. 818-833.
46. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A. Going deeper with convolutions, *Proceedings of the IEEE CVPR*, 2015. p. 1-9.
47. Wu S, Zhong S, Liu Y. Deep residual learning for image steganalysis. *Multimed Tools Appl.* 2018;77(9):10437-10453.
48. Kızrak MA, Bolat B. Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *BTD.* 2018;11(3):263-286.
49. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Commun. ACM.* 2017;60(6):84-90.
50. Kayaalp K, Süzen A. *Derin Öğrenme ve Türkiye’deki Uygulamaları.* Yayın Yeri: IKSAD International Publishing House, 2018;1.
51. Géron A. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems.* O’Reilly Media; 2019.
52. Doğan F, Türkoğlu İ. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *DUJE.* 2019;10(2):409-445.
53. Zhang L, Wang S, Liu B. *Deep learning for sentiment analysis: A survey.* Wiley Interdiscip Rev Data Min Knowl Discov. 2018;8(4):e1253.
54. Kilimci ZH, Akyokus S. Deep learning-and word embedding-based heterogeneous classifier ensembles for text classification. *Complexity*, 2018. p.1-8.

55. Ravì D, Wong C, Deligianni F, Berthelot M, Andreu-Perez J, Lo B, Yang G-Z. Deep learning for health informatics. *IEEE J Biomed Health Inform.* 2016;21(1):4-21.
56. Hinton GE, Osindero S, Teh Y-W. A fast learning algorithm for deep belief nets. *Neural Comput.* 2006;18(7):1527-1554.
57. Umut K, Yılmaz A, Dikmen Y. Sağlık alanında kullanılan derin öğrenme yöntemleri. *EJOSAT.* 2019;(16):792-808.
58. Minaee S, Boykov YY, Porikli F, Plaza AJ, Kehtarnavaz N, Terzopoulos D. Image segmentation using deep learning: A survey. *IEEE TPAMI.* 2021.p. 2-12.
59. Yaji A, Prasad S, Pai A. Artificial intelligence in dento-maxillofacial radiology. *Acta sci dent sci.* 2019;3(1):116-121.
60. Chollet F. Xception: Deep learning with depthwise separable convolutions. *Proceedings of the IEEE CVPR.* 2017; 1251-1258.
61. Redmon J, Farhadi A. YOLO9000: better, faster, stronger. *Proceedings of the IEEE CVPR.* 2017; 7263-7271.
62. Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation, *International Conference on MICCAI*, Springer, Cham, 2015. p. 234-241.
63. Milletari F, Navab N, Ahmadi SA. V-net: Fully convolutional neural networks for volumetric medical image segmentation, *2016 fourth international conference on 3D vision.* IEEE: 2016; 565-571.
64. Livne M, Rieger J, Aydin OU, Taha AA, Akay EM, Kossen T, Sobesky J, Kelleher JD, Hildebrand K, Frey D. A U-Net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease. *Front Neurosci.* 2019;(13):97.

65. Koç AB, Akgün D. U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması. EJOSAT. 2021;(26):407-414.
66. Toğaçar M, Ergen B. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. FÜMBD. 2019;31(1):109-121.
67. Jia Y, Shelhamer E, Donahue J, Karayev S, Long J, Girshick R, Guadarrama S, Darrell T. Caffe: Convolutional architecture for fast feature embedding, Proceedings of the 22nd ACM international conference on Multimedia, 2014. P. 675-678.
68. Khanna S. Artificial intelligence: contemporary applications and future compass. Int Dent J. 2010;60(4):269-272.
69. 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):508-522.
70. Katne T, Kanaparthi A, Srikanth Gotoor S, Muppirala S, Devaraju R, Gantala R. Artificial intelligence: demystifying dentistry–the future and beyond. Int J Contemp Med Surg Radiol. 2019;(4):D6-D9.
71. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, Dörfer C, Schwendicke F. Deep learning for the radiographic detection of periodontal bone loss. Sci Rep. 2019;9(1):1-6.
72. Davies A, Mannocci F, Mitchell P, Andiappan M, Patel S. The detection of periapical pathoses in root filled teeth using single and parallax periapical radiographs versus cone beam computed tomography–a clinical study. Int Endod J. 2015;48(6):582-592.

73. 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):1-11.
74. Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, Sveshnikov MM, Bednenko GB. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac Radiol.* 2019;48(4):20180051.
75. Orhan K, Bayrakdar I, 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):680-689.
76. Kılıc MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, Kaplan FA, Sağlam H, Odabaş A, Aslan AF. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofac Radiol.* 2021;50(2):200172.
77. Orhan K, Yazici G, Kolsuz ME, Kafa N, Bayrakdar IS, Çelik Ö. An Artificial Intelligence Hypothetical Approach for Masseter Muscle Segmentation on Ultrasonography in Patients With Bruxism. *J Adv Oral Res.* 2021;23(2):2068211005611.
78. 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):635-642.
79. 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.* 2020;1-7.

80. Miki Y, Muramatsu C, Hayashi T, Zhou X, Hara T, Katsumata A, Fujita H In Tooth labeling in cone-beam CT using deep convolutional neural network for forensic identification, *Medical Imaging 2017: Computer-Aided Diagnosis*. SPIE: 2017. p. 101343E.
81. Muramatsu C, Kutsuna S, Takahashi R, Hayashi T, Nishiyama W, Ariji Y, Zhou X, Hara T, Katsumata A, Ariji E In Tooth numbering in cone-beam CT using a relation network for automatic filing of dentition charts, *Medical Imaging 2020: Imaging Informatics for Healthcare, Research, and Applications*. SPIE: 2020. P. 113180L.
82. Jang TJ, Kim KC, Cho HC, Seo JK. A fully automated method for 3D individual tooth identification and segmentation in dental CBCT. *arXiv preprint arXiv:2102.06060* 2021.
83. Pauwels R, Brasil DM, Yamasaki MC, Jacobs R, Bosmans H, Freitas DQ, Haiter-Neto F. Artificial intelligence for detection of periapical lesions on intraoral radiographs: Comparison between convolutional neural networks and human observers. *Oral Surg Oral Med Oral Radiol*. 2021;131(5):610-616.
84. Kise Y, Ikeda H, Fujii T, Fukuda M, Ariji Y, Fujita H, Katsumata A, Ariji E. Preliminary study on the application of deep learning system to diagnosis of Sjögren's syndrome on CT images. *Dentomaxillofac Radiol*. 2019;48(6):20190019.
85. 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.
86. Xie X, Wang L, Wang A. Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *Angle Orthod*. 2010;80(2):262-266.

87. Birnbaum NS, Aaronson HB. Dental impressions using 3D digital scanners: virtual becomes reality. *Compend Contin Educ Dent* 2008;29(8):494-496.
88. Mackin N, Sims-Williams J, Stephens C. Artificial intelligence in the dental surgery: an orthodontic expert system, a dental tool of tomorrow. *Dent. Update* 1991;18(8):341-343.
89. Hwang H-W, Park J-H, Moon J-H, Yu Y, Kim H, Her S-B, Srinivasan G, Aljanabi MNA, Donatelli RE, Lee S-J. Automated identification of cephalometric landmarks: Part 2-Might it be better than human? *Angle Orthod.* 2020;90(1):69-76.
90. Yu H, Cho S, Kim M, Kim W, Kim J, Choi J. Automated skeletal classification with lateral cephalometry based on artificial intelligence. *J Dent Res.* 2020;99(3):249-256.
91. Choi H-I, Jung S-K, Baek S-H, Lim WH, Ahn S-J, Yang I-H, Kim T-W. Artificial intelligent model with neural network machine learning for the diagnosis of orthognathic surgery. *J Craniofacial Surg.* 2019;30(7):1986-1989.
92. K k H, Acilar AM,  zgi MS. Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Prog Orthod.* 2019;20(1):1-10.
93. Kunz F, Stellzig-Eisenhauer A, Zeman F, Boldt J. Artificial intelligence in orthodontics. *J Orofac Orthop.* 2020;81(1):52-68.
94. Flores-Mir C, Nebbe B, Major PW. Use of skeletal maturation based on hand-wrist radiographic analysis as a predictor of facial growth: a systematic review. *Angle Orthod.* 2004;74(1):118-124.
95. Ruppin J, Popovic A, Strauss M, Sp ntrup E, Steiner A, Stoll C. Evaluation of the accuracy of three different computer-aided surgery systems in dental implantology:

- optical tracking vs. stereolithographic splint systems. *Clin Oral Implants Res.* 2008;19(7):709-716.
96. Widmann G. Image-guided surgery and medical robotics in the cranial area. *Biomed Imaging Interv J.* 2007;3(1).
97. Zhang W, Li J, Li Z-B, Li Z. Predicting postoperative facial swelling following impacted mandibular third molars extraction by using artificial neural networks evaluation. *Sci Rep.* 2018;8(1):1-9.
98. 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.* 2020;122(4):333-337.
99. Yoo J-H, Yeom H-G, Shin W, Yun JP, Lee JH, Jeong SH, Lim HJ, Lee J, Kim BC. Deep learning based prediction of extraction difficulty for mandibular third molars. *Sci Rep.* 2021;11(1):1-9.
100. Le Y, Verdonshot E. Performance of diagnostic systems in occlusal caries detection compared. *Community Dent Oral Epidemiol.* 1994;22(3):187-191.
101. Pine CM, Jaap J. Dynamics of and diagnostic methods for detecting small carious lesions. *Caries Res.* 1996;30(6):381-388.
102. Ten Cate J. What dental diseases are we facing in the new millennium: some aspects of the research agenda. *Caries Res.* 2001;35(Suppl. 1):2-5.
103. Akpata E, Farid M, Al-Saif K, Roberts E. Cavitation at radiolucent areas on proximal surfaces of posterior teeth. *Caries Res.* 1996;30(5):313-316.
104. Heaven T, Weems R, Firestone A. The use of a computer-based image analysis program for the diagnosis of approximal caries from bitewing radiographs. *Caries Res.* 1994;28(1):55-58.

105. Duncan RC, Heaven T, Weems RA, Firestone AR, Greer DF, Patel JR. Using computers to diagnose and plan treatment of approval caries detected in radiographs. *J Am Dent Assoc.* 1995;126(7):873-882.
106. Wenzel A. Computer-automated caries detection in digital bitewings: consistency of a program and its influence on observer agreement. *Caries Res.* 2001;35(1):12-20.
107. Srivastava MM, Kumar P, Pradhan L, Varadarajan S. Detection of tooth caries in bitewing radiographs using deep learning. *arXiv preprint arXiv:1711.07312* 2017.
108. 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;100103425.
109. Askar H, Krois J, Rohrer C, Mertens S, Elhennawy K, Ottolenghi L, Mazur M, Paris S, Schwendicke F. Detecting white spot lesions on dental photography using deep learning: A pilot study. *J Dent.* 2021;107103615.
110. Casalegno F, Newton T, Daher R, Abdelaziz M, Lodi-Rizzini A, Schürmann F, Krejci I, Markram H. Caries detection with near-infrared transillumination using deep learning. *J Dent Res.* 2019;98(11):1227-1233.
111. 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):106-111.
112. Lee J-H, Lee J-S, Choi J-K, Kweon H-I, Kim Y-T, Choi S-H. National dental policies and socio-demographic factors affecting changes in the incidence of periodontal treatments in Korean: a nationwide population-based retrospective cohort study from 2002–2013. *BMC Oral Health* 2016;16(1):1-9.

113. Furman E, Jasinevicius TR, Bissada NF, Victoroff KZ, Skillicorn R, Buchner M. Virtual reality distraction for pain control during periodontal scaling and root planing procedures. *J Am Dent Assoc.* 2009;140(12):1508-1516.
114. Sohmura T, Kusumoto N, Otani T, Yamada S, Wakabayashi K, Yatani H. CAD/CAM fabrication and clinical application of surgical template and bone model in oral implant surgery. *Clin Oral Implants Res.* 2009;20(1):87-93.
115. 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):114-123.
116. Alalharith DM, Alharthi HM, Alghamdi WM, Alsenbel YM, Aslam N, Khan IU, Shahin SY, Dianišková S, Alhareky MS, Barouch KK. A Deep Learning-Based Approach for the Detection of Early Signs of Gingivitis in Orthodontic Patients Using Faster Region-Based Convolutional Neural Networks. *Int J Environ Res.* 2020;17(22):8447.
117. 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.
118. 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.
119. Bayrakdar SK, 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):1-9.

120. Lim K, Moles D, Downer M, Speight P. Opportunistic screening for oral cancer and precancer in general dental practice: results of a demonstration study. *Br Dent J.* 2003;194(9):497-502.
121. Rosmai MD, Sameemii AK, Basir A, Mazlipahiv IS, Norzaidi M. The use of artificial intelligence to identify people at risk of oral cancer: empirical evidence in Malaysian University. *Int J Sci Res.* 2010;3(1):10-20.
122. Ilhan B, Lin K, Guneri P, Wilder-Smith P. Improving oral cancer outcomes with imaging and artificial intelligence. *J Dent Res.* 2020;99(3):241-248.
123. Kar A, Wreesmann VB, Shwetha V, Thakur S, Rao VU, Arakeri G, Brennan PA. Improvement of oral cancer screening quality and reach: The promise of Artificial Intelligence. *J Oral Pathol Med.* 2020;49(8):727-730.
124. Shamim MZM, Syed S, Shiblee M, Usman M, Ali S. Automated detection of oral pre-cancerous tongue lesions using deep learning for early diagnosis of oral cavity cancer. *arXiv preprint arXiv:1909.08987* 2019.
125. De Tobel J, Radesh P, Vandermeulen D, Thevissen PW. An automated technique to stage lower third molar development on panoramic radiographs for age estimation: a pilot study. *J. Forensic Odonto-Stomatol.* 2017;35(2):42.
126. Patil V, Vineetha R, Vatsa S, Shetty DK, Raju A, Naik N, Malarout N. Artificial neural network for gender determination using mandibular morphometric parameters: A comparative retrospective study. *Cogent Eng.* 2020;7(1):1723783.
127. Niño-Sandoval TC, Pérez SVG, González FA, Jaque RA, Infante-Contreras C. Use of automated learning techniques for predicting mandibular morphology in skeletal class I, II and III. *Forensic Sci Int.* 2017;281: e1-187. e7.

128. Mozzo P, Procacci C, Tacconi A, Martini PT, Andreis IB. A new volumetric CT machine for dental imaging based on the cone-beam technique: preliminary results. *Eur Radiol.* 1998;8(9):1558-1564.
129. Menziletoğlu D, Işık BK, Güler AY. Reasons of cone-beam computed tomography requests in oral and maxillofacial surgery. *Yeditepe J Dent.* 2019;15(1):70-75.
130. Robb RA. The dynamic spatial reconstructor: an x-ray video-fluoroscopic CT scanner for dynamic volume imaging of moving organs. *IEEE Trans Med.* 1982;1(1):22-33.
131. Harorlı A, Akgul M, Dagistan S. *Diş Hekimliği Radyolojisi Kitabı.* Atatürk Üniversitesi Yayınları 2006;80-150.
132. Tsiklakis K, Syriopoulos K, Stamatakis H. Radiographic examination of the temporomandibular joint using cone beam computed tomography. *Dentomaxillofac Radiol.* 2004;33(3):196-201.
133. Tsiklakis K, Donta C, Gavala S, Karayianni K, Kamenopoulou V, Hourdakis CJ. Dose reduction in maxillofacial imaging using low dose Cone Beam CT. *Eur J Radiol.* 2005;56(3):413-417.
134. Da Silva FC, Bezerra ISQ, Rebellato NLB, de Lima AAS. Cone beam computed tomography and applicability in Dentistry-literature review. *RSBO* 2013;10(3):272-277.
135. Tyndall DA, Rathore S. Cone-beam CT diagnostic applications: caries, periodontal bone assessment, and endodontic applications. *Dent Clin N Am.* 2008;52(4):825-841.
136. Scarfe WC, Farman AG. What is cone-beam CT and how does it work? *Dent Clin N Am.* 2008;52(4):707-730.

137. Ertař E, Arslan H, apar İ, Gök T, Ertař H. Endodontide Konik Iřınlı Bilgisayarlı Tomografi. Atatürk Üniversitesi Diř Hekimlięi Fakóltesi Dergisi 24(1):113-118.
138. Miracle A, Mukherji S. Conebeam CT of the head and neck, part 1: physical principles. Am J Neuroradiol. 2009;30(6):1088-1095.
139. Macleod I, Heath N. Cone-beam computed tomography (CBCT) in dental practice. Dent. update 2008;35(9):590-598.
140. Agrawal JM, Agrawal MS, Nanjannawar LG, Parushetti AD. CBCT in orthodontics: the wave of future. J Contemp Dent Pract. 2013;14(1):153.
141. Orhan K, Özemre MÖ, Segin CK, Gülřahi A. Alt Anterior Diřlerin Kök Kanal Morfolojisinin Konik Iřınlı Bilgisayarlı Tomografi Kullanılarak Deęerlendirilmesi. Turkiye Klinikleri J Dental Sci. 2018;24(3):190-196.
142. Orhan K, Karslıoęlu H, Özemre MÖ, Köseoęlu Segin C, Kamburoęlu K. Kondil Hacmi ve řeklinin Konik Iřınlı Bilgisayarlı Tomografi Kullanılarak Deęerlendirilmesi. Turkiye Klinikleri J Dental Sci. 2021;27(2).
143. Orhan K, Özemre MÖ, Segin CK, Gülřahi A. Mandibular Kanalın Seyri: Retrospektif alıřma. Turkiye Klinikleri J Dental Sci. 2019;25(2):140-145.
144. Lin T-Y, Maire M, Belongie S, Hays J, Perona P, Ramanan D, Dollár P, Zitnick CL. In Microsoft coco: Common objects in context, European conference on computer. Springer, Cham, 2014. p. 740-755.
145. He K, Zhang X, Ren S, Sun J. In Deep residual learning for image recognition, Proceedings of the IEEE CVPR. 2016. p. 770-778.
146. Söylemez Ö, Tümen V, Söylemez N, Ergen B. A Deep Facial Expression Analysis Application Conducted with Inception Architecture.

147. Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z In Rethinking the inception architecture for computer vision, Proceedings of the IEEE CVPR. 2016. p. 2818-2826.
148. Urlu ME. Konvolüsyonel yapay sinir ağları ve ileri görüntü işleme teknikleri ile tehlikeli madde tespiti ve sınıflandırılması.
149. Szegedy C, Ioffe S, Vanhoucke V. Inception-v4, Inception-Resnet And The Impact of Residual Connections On Learning. In Thirty-first AAAI conference on artificial intelligence 2017.
150. 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):250-261.
151. Santra A, Christy CJ. Genetic algorithm and confusion matrix for document clustering. IJCSI. 2012;9(1):322.
152. Ozenne B, Subtil F, Maucort-Boulch D. The precision–recall curve overcame the optimism of the receiver operating characteristic curve in rare diseases. J Clin Epidemiol. 2015;68(8):855-859.
153. Cook JA. ROC curves and nonrandom data. Pattern Recognit Lett. 2017;(85):35-41.
154. Dirican A. Tanı testi performanslarının değerlendirilmesi ve kıyaslanması. Cerrahpasa Med J. 2001;32(1):25-30.
155. Tomak L, Yüksel B. İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması. J Exp Clin Med . 2009;27(2).
156. Pinchi V, Pradella F, Vitale G, Rugo D, Nieri M, Norelli G-A. Comparison of the diagnostic accuracy, sensitivity and specificity of four odontological methods for

- age evaluation in Italian children at the age threshold of 14 years using ROC curves. *Med Sci Law*. 2016;56(1):13-18.
157. Zweig MH, Campbell G. Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. *Clin Chem*. 1993;39(4):561-577.
158. Davis J, Goadrich M In The relationship between Precision-Recall and ROC curves, *Proceedings of the 23rd international conference on Machine learning*. 2006 p. 233-240.
159. Barr A, Feigenbaum EA. *The Handbook of Artificial Intelligence*. William Kaufmann. Inc., Los Altos, CA 1981;1.
160. Shan T, Tay F, Gu L. Application of artificial intelligence in dentistry. *J Dent Res*. 2021;100(3):232-244.
161. Wang L, Wang D, Zhang Y, Ma L, Sun Y, Lv P. An automatic robotic system for three-dimensional tooth crown preparation using a picosecond laser. *Lasers Surg Med*. 2014;46(7):573-581.
162. Bouchahma M, Hammouda SB, Kouki S, Alshemali M, Samara K In An automatic dental decay treatment prediction using a deep convolutional neural network on X-ray images, *2019 IEEE/ACS 16th International Conference on Computer Systems and Applications (AICCSA)*. IEEE, 2019. p. 1-4.
163. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, Schwendicke F. Deep learning for the radiographic detection of apical lesions. *J Endod*. 2019;45(7):917-922.
164. Takahashi T, Nozaki K, Gonda T, Ikebe K. A system for designing removable partial dentures using artificial intelligence. Part 1. Classification of partially edentulous arches using a convolutional neural network. *J Prosthodont Res*. 2021;(65):115-118.

165. De Dumast P, Mirabel C, Cevidanes L, Ruellas A, Yatabe M, Ioshida M, Ribera NT, Michoud L, Gomes L, Huang C. A web-based system for neural network based classification in temporomandibular joint osteoarthritis. *Comput Med Imaging Graph.* 2018;(67):45-54.
166. 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;103101816.
167. 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.
168. Flint DJ, Paunovich E, Moore WS, Wofford DT, Hermes CB. A diagnostic comparison of panoramic and intraoral radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 1998;85(6):731-735.
169. Akarslan Z, Akdevelioglu M, Gungor K, Erten H. A comparison of the diagnostic accuracy of bitewing, periapical, unfiltered and filtered digital panoramic images for approximal caries detection in posterior teeth. *Dentomaxillofac Radiol.* 2008;37(8):458-463.
170. White SC, Pharoah MJ. *Oral radiology-E-Book: Principles and interpretation.* Baskı. Elsevier Health Sciences; 2014.
171. 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.
172. 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):337-343.
173. Kuwada C, Ariji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, Ariji E. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surg. Oral Med. Oral Pathol. Oral Radiol.* 2020;130(4):464-469.
174. Bayrakdar Sk, Çelik Ö, Bayrakdar Iş, Orhan K, Bilgir E, Odabas A, Aslan Af. Success Of Artificial Intelligence System In Determining Alveolar Bone Loss From Dental Panoramic Radiography ImageS. *CDJ.* 23(4):318-324.
175. 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.
176. Yang H, Jo E, Kim HJ, Cha I-h, Jung Y-S, Nam W, Kim J-Y, Kim J-K, Kim YH, Oh TG. Deep learning for automated detection of cyst and tumors of the jaw in panoramic radiographs. *J Clin Med.* 2020;9(6):1839.
177. Watanabe H, Ariji Y, Fukuda M, Kuwada C, Kise Y, Nozawa M, Sugita Y, Ariji E. Deep learning object detection of maxillary cyst-like lesions on panoramic radiographs: preliminary study. *Oral Radiol.* 2021;37(3):487-493.
178. 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.
179. Kuwada C, Ariji Y, Kise Y, Funakoshi T, Fukuda M, Kuwada T, Gotoh K, Ariji 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.

180. 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.* 2021;50(2):10246.
181. 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* 2020;11(2):100.
182. 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):114-123.
183. Kyventidis N, Angelopoulos C. Intraoral radiograph anatomical region classification using neural networks. *Int J Comput Assist Radiol Surg.* 2021;16(3):447-455.
184. 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 International (Berlin, Germany: 1985)* 2021;0-0.
185. 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):275-281.
186. 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;8:97296-309.
187. Li Q, Chen K, Han L, Zhuang Y, Li J, Lin J. Automatic tooth roots segmentation of cone beam computed tomography image sequences using U-net and RNN. *J X-ray Sci Technol.* 2020;28(5):905-922.

188. 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):333-337.
189. 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.
190. Leite AF, Van Gerven A, Willems H, Beznik T, Lahoud P, Gaêta-Araujo H, Vranckx M, Jacobs R. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clin Oral Investig.* 2020;1-11.
191. Muramatsu C, Morishita T, Takahashi R, Hayashi T, Nishiyama W, Arijji Y, Zhou X, Hara T, Katsumata A, Arijji E. Tooth detection and classification on panoramic radiographs for automatic dental chart filing: improved classification by multi-sized input data. *Oral Radiol.* 2021;37(1):13-19.
192. Bilgir E, Bayrakdar İŞ, Çelik Ö, Orhan K, Akkoca F, Sağlam H, Odabaş A, Aslan AF, Ozcetin C, Kılı M. An artificial intelligence approach to automatic tooth detection and numbering in panoramic radiographs. *BMC Med Imaging* 2021;21(1):1-9.
193. Redmon J, Divvala S, Girshick R, Farhadi A In You only look once: Unified, real-time object detection, *Proceedings of the IEEE CVPR.* 2016. p. 779-788.
194. Girshick R, Donahue J, Darrell T, Malik J. Region-based convolutional networks for accurate object detection and segmentation. *IEEE TPAMI* 2015;38(1):142-158.
195. Tan FG, Yüksel AS, Aydemir E, Ersoy M. Derin Öğrenme Teknikleri İle Nesne Tespiti Ve Takibi Üzerine Bir İnceleme. *EJOSAT* 2021;(25):159-171.
196. Girshick R, Fast R. *IEEE Int. Conf. Comput. Vis. Santiago, Chile, December 2015*;7-13.

197. Tang Y. Deep learning using linear support vector machines. arXiv preprint arXiv:1306.0239 2013.
198. Chen S, Mulgrew B, Grant PM. A clustering technique for digital communications channel equalization using radial basis function networks. IEEE Trans. Neural Netw. 1993;4(4):570-590.
199. Kaiming H, Gkioxari G, Dollar P, Girshick R. Mask R-CNN. Proceedings of the IEEE ICCV. 2017. p. 2961-2969.
200. Ömeroğlu A, Kumbasar N, Oral E, Özbek İ. Hangar Detection with Mask R-CNN Algorithm.
201. Szegedy C, Ioffe S, Vanhoucke V, Alemi AA. Inception-v4, inception-resnet and the impact of residual connections on learning, Thirty-first AAAI conference on artificial intelligence. 2017. p. 4278-4283.
202. Akdik DK. Semantik segmentasyon ve stereo görme teknikleri kullanılarak canlı havan ağırlığının tahmini üzerine bir çalışma. Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı. Yüksek Lisans Tezi, İstanbul: Maltepe Üniversitesi, 2021.
203. Koçer S, Akdağ A. Convolutional neural network based handgun detection. 3rd Int. Conf. Comput. Sci. Eng. IEEE: 2017; 89-93.
204. Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation, Proceedings of the IEEE CVPR. 2015; 3431-3440.
205. Eker AG, Nevcihan D. Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları. Acta Infologica 5(2):13-14.
206. Lee J, Chung M, Lee M, Shin Y-G. Tooth Instance Segmentation from Cone-Beam CT Images through Point-based Detection and Gaussian Disentanglement. arXiv preprint arXiv:2102.01315 2021.

207. 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.
208. Cui Z, Li C, Wang W In 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. p. 6368-6377.
209. Chung M, Lee M, Hong J, Park S, Lee J, Lee J, Yang I-H, Lee J, Shin Y-G. Pose-aware instance segmentation framework from cone beam CT images for tooth segmentation. *Comput Biol Med*. 2020;120,103720.
210. Wu X, Chen H, Huang Y, Guo H, Qiu T, Wang L. Center-sensitive and boundary-aware tooth instance segmentation and classification from cone-beam CT. *IEEE 17th ISBI*. IEEE: 2020. p. 939-942.

EKLER

EK-1. ÖZGEÇMİŞ

1. KİŞİSEL BİLGİLER

ADI, SOYADI	Hande SAĞLAM
DOĞUM TARİHİ VE YERİ	
HALEN GÖREVİ	Araştırma Görevlisi (Araş. Gör. Hande Sağlam)
YAZIŞMA ADRESİ	ESOGÜ Diş Hekimliği Fakültesi Oral Diagnoz ve Radyoloji ABD Meşelik Kampüsü-Eskişehir
TELEFON:	
E-MAIL:	

2. EĞİTİM

YILI	DERECESİ	ÜNİVERSİTE	ÖĞRENİM ALANI
2012	Lisans	Gazi Üniversitesi	Diş Hekimliği
2019	Uzmanlık	Osmangazi Üniversitesi	Oral Diagnoz ve Radyoloji

3. AKADEMİK DENEYİM

GÖREV DÖNEMİ	ÜNVAN	BÖLÜM	ÜNİVERSİTE
2019-2022	Araş. Gör.	Diş Hekimliği Fakültesi	Osmangazi Üniversitesi

4. ÇALIŞMA ALANLARI

ÇALIŞMA ALANI	ANAHTAR SÖZCÜKLER
Oral Diagnoz ve Radyoloji	Oral Diagnoz ve Radyoloji

5. SON BEŞ YILDAKİ ÖNEMLİ YAYINLAR

1. Sağlam H., Arı T., 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 In Health Sciences) ISSN: 2757-9646, 1(2), 26-33.
2. Bilgir E., Bayrakdar, İ. Ş. Çelik, Ö., Orhan K., Akkoca F., Sağlam H., Odabaş A., Aslan AF., Özçetin C., Kılılı M., Rozylo-Kalinowska I. (2021). An artificial intelligence approach to automatic tooth detection and numbering in panoramic radiographs. BMC Medical Imaging, 21(1), 1-9.
3. Kılıç M.C., Bayrakdar, İ. Ş., Çelik Ö., Bilgir E., Orhan K., Aydın O. B., Akkoca F., Sağlam H., Odabaş A., Yılmaz A. B. (2021). Artificial İntelligence System For Automatic Deciduous Tooth Detection And Numbering İn Panoramic Radiographs. Dentomaxillofacial Radiology, 50, 20200172.
4. Sağlam H., Arı T., Bayrakdar İ. Ş., Bilgir E., Açıkalın M. F., Başaran D. Sert Damakta Mavi Nevus: Olgu Raporu. 7tepe Klinik Dergisi, 17(3), 235-238.
5. Sağlam H., Akkoca Kaplan F., Bayrakdar İ. Ş., Açıkalın M. F., Özgül Z., Şensoy E., Hayıt B. (2021). Ağızda Görülen Epitelyal Displazi ve Skuamöz Hücreli Karsinom Vakalarının Değerlendirilmesi: Vaka Serisi. Türkiye Klinikleri. Diş Hekimliği Bilimleri Dergisi, 27(2).
6. Sağlam H., Kaplan F. A., Bayrakdar İ. Ş. Sunray Appearance On Sonography In Osteosarcoma Of The Mandible: A Rare Case Report. Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi, 31(3), 439-443.

EK-2. ETİK KURUL ONAYI



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

Sayı : 25403353-050.99-E.51835
Konu : 2020 - 177 Karar

03/06/2020

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

Karar Tarihi: 12.05.2020
Karar Sayısı: 17

Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı öğretim üyesi Doç.Dr.İbrahim Şevki BAYRAKDAR'ın sorumluluğunda yürütülecek olan "**Derin Öğrenme Yöntemine Dayalı Yapay Zekâ Algoritmalarıyla Konik Işınlı Bilgisayarlı Tomografi Görüntülerinde Dişlerin Tespit Edilmesi ve Numaralandırılması**" başlıklı araştırmanın/çalışmanın gerçekleştirilmesinde etik ve bilimsel açıdan sakınca bulunmadığına karar verilmiştir.

Bilgilerinizi ve gereğini saygı ile rica ederim.

Prof. Dr. Varol ŞAHİNTÜRK
Kurul Başkanı

Ek: e-imzalı Etik Kurul Kararı

Bu evrak 5070 sayılı Elektronik İmza Kanunu'na göre elektronik olarak imzalanmıştır. Evrak doğrulama adresi:
<https://ebysnetm.ogu.edu.tr/Home/Dogrulama/cbe26f24-3e3b-4bda-b441-6f90ec743f71>

Adres	: Meşelik Kampüsü 26040 Odunpazarı	Ayrıntılı Bilgi	: Aysun SERTTAŞ
Telefon	: 0222 2392979-4690	Faks	: 222 239 37 72
E-Posta	: aserttas@ogu.edu.tr	Elektronik Ağ	: http://girisimselolmayanetikkurul.ogu.edu.tr/
		KEP Adresi	: esk.osmangaziunirek@hs01.kep.tr



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

Prof.Dr.Varol ŞAHİNTÜRK
(Başkan)
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
Histoloji ve Embriyoloji 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 ŞAYLIĞIL
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi Tıp Tarihi ve Etik AD

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

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

Prof.Dr.Merih ÖZGEN
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
Fizik Tedavi ve Rehabilitasyon AD

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

Doç.Dr.Suzan ŞAYLISOY
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
Radyoloji AD

Doç.Dr.Lütfiye DEMİR
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
İç Hast. AD / Tıbbi Onkoloji BD

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

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

Dr.Öğr.Üy.Mustafa Değer
BİLGEÇ
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi Göz Hastalıkları AD

Av. Önder CAN
Avukat

Etik Kurul Sekreterliği
Aysun SERTTAS
Tel: 0 382 254 4690

Bu evrak 5070 sayılı Elektronik İmza Kanunu'na göre elektronik olarak imzalanmıştır. Evrak doğrulama adresi:
<https://ebysnetm.ogu.edu.tr/Home/Dogrulama/43c93af7-e71c-4292-9093-6cf841f5896>



KARAR FORMU

<p>Başvuru Tarihi: 28.04.2020</p>	<p>Çalışmanın Başlığı: “Derin Öğrenme Yöntemine Dayalı Yapay Zekâ Algoritmalarıyla Konik Işınlı Bilgisayarlı Tomografi Görüntülerinde Dişlerin Tespit Edilmesi ve Numaralandırılması”</p> <p>Çalışmacılar: Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı - Doç.Dr.İbrahim Şevki BAYRAKDAR (Tez Danışmanı), Arş.Gör.Dt.Hande SAĞLAM (Tez Sahibi), Eskişehir Osmangazi Üniversitesi Fen - Edebiyat Fakültesi Matematik-Bilgisayar Bölümü - Dr.Öğr.Üy.Özer ÇELİK</p>
<p>Çalışmanın değerlendirildiği ilk toplantı tarihi: 12.05.2020</p>	<p>Sonuç: 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 ilettiği oldukları sorumlulukları yerine getirmeleri beklenmektedir.</p>
<p>Karar Tarihi: 12.05.2020</p> <p>Karar No: 17</p>	<p>Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı öğretim üyesi Doç.Dr.İbrahim Şevki BAYRAKDAR'ın sorumluluğunda yürütülecek olan “Derin Öğrenme Yöntemine Dayalı Yapay Zekâ Algoritmalarıyla Konik Işınlı Bilgisayarlı Tomografi Görüntülerinde Dişlerin Tespit Edilmesi ve Numaralandırılması” başlıklı araştırma/çalışma gereç, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve uygun bulunmuş olup, araştırmanın/çalışmanın gerçekleştirilmesinde etik ve bilimsel yönden sakınca bulunmadığına oy birliği ile karar verilmiştir.</p> <p>Araştırmacılara başarılar dileriz.</p>



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

Çalışmanın Başlığı: “Derin Öğrenme Yöntemine Dayalı Yapay Zekâ Algoritmalarıyla Konik Işınlı Bilgisayarlı Tomografi Görüntülerinde Dişlerin Tespit Edilmesi ve Numaralandırılması”

GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU		
Unvanı/Adı/Soyadı	Kurumu	İmza
1 Prof.Dr.Varol ŞAHİNTÜRK (Başkan)	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Histoloji ve Embriyoloji AD	e-İmzalıdır
2 Prof.Dr.Hava ÜSKÜDAR TEKE (Başkan Yardımcısı)	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi İç Hastalıkları AD / Hematoloji BD	e-İmzalıdır
3 Doç.Dr.Ferdi KÖŞGER (Raportör)	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Ruh Sağlığı ve Hastalıkları AD	e-İmzalıdır
4 Prof.Dr.Ömür ŞAYLIGİL	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Tıp Tarihi ve Etik AD	e-İmzalıdır
5 Prof.Dr.Setenay DİNÇER ÖNER	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Biyostatistik AD	e-İmzalıdır
6 Prof.Dr.Batu Can YAMAN	Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Restoratif Diş Tedavisi AD	e-İmzalıdır
7 Prof.Dr.Merih ÖZGEN	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Fizik Tedavi ve Rehabilitasyon AD	e-İmzalıdır
8 Prof.Dr.Özlem ÖRSAL	Eskişehir Osmangazi Üniversitesi Sağlık Bilimleri Fakültesi Halk Sağlığı Hemşireliği AD	e-İmzalıdır
9 Doç.Dr.Suzan ŞAYLISOY	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Radyoloji AD	e-İmzalıdır
10 Doç.Dr.Lütfiye DEMİR	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi İç Hastalıkları AD / Tıbbi Onkoloji BD	e-İmzalıdır
11 Doç.Dr.Gökür YORULMAZ	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi İç Hastalıkları AD / Endokrinoloji ve Metabolizma Hastalıkları BD	e-İmzalıdır
12 Doç.Dr.Melih VELİPAŞAOĞLU	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Kadın Hastalıkları ve Doğum AD	e-İmzalıdır
13 Doç.Dr.Zeren BARIŞ	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Çocuk Sağ. ve Hast. AD / Çocuk Gastroenterolojisi BD	-
14 Dr.Öğr.Üy.Mustafa Değer BİLGEÇ	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Göz Hastalıkları AD	-
15 Av.Önder CAN	Hukuk	-

E-İmzalıdır

Bu evrak 5070 sayılı Elektronik İmza Kanunu'na göre elektronik olarak imzalanmıştır. Evrak doğrulama adresi:
<https://ebysnetm.ogu.edu.tr/Home/Dogrulama/43c93af7-e71c-4292-9093-6cf841f5896>

