



BEZMİALEM VAKIF ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ
ANABİLİM DALI

**DAİMİ DENTİSYONDA MANDİBULAR İKİNCİ MOLAR DİŞLERİN KÖK
OLUŞUM SEVİYELERİNİN YAPAY ZEKÂ İLE DEĞERLENDİRİLEREK
ÇEKİM ENDİKASYONU OLAN BİRİNCİ MOLAR DİŞLERİN İDEAL
ÇEKİM ZAMANININ BELİRLENMESİ**

UZMANLIK TEZİ

Ayşe Meryem ALTIN

Tez Danışmanı: Dr. Öğretim Üyesi İrfan Sarıca

Eylül 2023



BEZMİALEM VAKIF ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ
ANABİLİM DALI

DAİMİ DENTİSYONDA MANDİBULAR İKİNCİ MOLAR DİŞLERİN KÖK
OLUŞUM SEVİYELERİNİN YAPAY ZEKÂ İLE DEĞERLENDİRİLEREK
ÇEKİM ENDİKASYONU OLAN BİRİNCİ MOLAR DİŞLERİN İDEAL
ÇEKİM ZAMANININ BELİRLENMESİ

UZMANLIK TEZİ

Ayşe Meryem ALTIN

Tez Danışmanı: Dr. Öğretim Üyesi İrfan Sarıca

Eylül 2023

TEŞEKKÜR

Uzmanlık eğitimim ve tez çalışmam sürecinde bilgi ve tecrübeleri ile bana yol gösteren, anlayış ve hoşgörüsü ile desteğini her zaman hissettiğim, değerli hocam ve tez danışmanım, Sayın Dr. Öğr. Üyesi İrfan SARICA'ya;

Uzmanlık eğitimine ilk başladığım yılda birlikte çalışma imkanı bulduğum, bilgi ve tecrübelerinden yararlandığım, emeğini ve ilgisini esirgemeyen değerli hocam Sayın Dr. Öğr. Üyesi Tuğba ÜNVER'e;

Uzmanlık eğitimim boyunca her koşulda klinik ve akademik bilgisini benimle paylaşan, her türlü yardım ve desteği fedakârlık ve içtenlikle gösteren, çok değerli hocam Sayın Dr. Öğr. Üyesi Elifhan ALAGÖZ'e;

Aralarına katıldığım ilk günden beri üzerimde maddi manevi büyük emeği olan, teorik ve pratiğe dair kendisinden çok şey öğrendiğim, çalışmasıyla bana örnek olan, yol açan, güler yüzünü, yakınlığını ve desteğini her zaman hissettiğim, her konuda fikrine danıştığım, çok kıymetli arkadaşım ve hocam Sayın Uzm. Dt Nilüfer KARAÇAY'a;

Planlanan tez çalışmamın gerçekleşmesinde büyük emek ve katkılarından dolayı Sayın Doç. Dr. Elif BİLGİR'e;

Tanıymış olmaktan büyük mutluluk duyduğum, birlikte çalışmaktan zevk aldığım, sevgi ve desteklerini her zaman hissettiğim, huzurlu ve sıcak bir aile ortamı sağlayan, çok sevgili mesai arkadaşlarım Dt. Büşra SINMAZ, Dt. Ebrar ERSARI, Dt. Emine Rana SARIKAYA, Dt. Enes Ergin ORUÇ ve Dt. Nilüfer GÜRSOY'a;

Bana olan güvenlerini her daim yanımda hissettiğim, maddi manevi desteklerini her zaman olduğu gibi tez yazım aşamamda da eksik etmeyen çok kıymetli arkadaşlarım Elif MERTOĞLU ve Şeydanur DEMİROK'a;

Eğitim hayatım boyunca tüm kırılma noktalarımda yol göstericiliği ile, verdiği motivasyonla, maddi manevi desteği ile büyük etkiye sahip çok kıymetli hocam Erhan OKUMUŞ ve kıymetli eşi Elif OKUMUŞ'a;

Beni büyüten ve yetiştiren, hayatım boyunca her konuda yanımda olan, her zaman sevgi, merhamet ve şefkatle muamele eden, varlıkları sevinç ve mutluluk kaynağım olan, dualarını üzerimde hissettiğim, canım annem Kadriye GEÇİMLİ, babam Dursun Selman GEÇİMLİ ve kardeşim Rabia GEÇİMLİ'ye;

Tanıştığımız günden beri üzüntümü ve mutluluğumu paylaştığım her anımda yanımda olan, varlığıyla bana büyük güç, neşe ve güven veren, bu zorlu süreçte desteğini hiçbir zaman esirgemeyen, çok kıymetli eşim Muhammed ALTIN'a;

en derinden minnet ve teşekkürlerimi sunarım...

AYŞE MERYEM ALTIN

BEYAN

Bu tezin kendi alıřmam olduėunu, planlanmasından yazımına kadar hibir ařamasında etik dıřı davranıřımın olmadıėını, tezdeki bütn bilgileri akademik ve etik kurallar iinde elde ettiėimi, tez alıřmasıyla elde edilmeyen bütn bilgi ve yorumlara kaynak gsterdiėimi ve bu kaynakları kaynaklar listesine aldıėımı, tez alıřması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranıřımın olmadıėını beyan ederim.

Ayře Meryem Altın



İÇİNDEKİLER

TEŞEKKÜR.....	iii
BEYAN.....	iv
İÇİNDEKİLER	v
TABLO LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
ÖZET	xii
SUMMARY	xiv
1. GİRİŞ VE AMAÇ.....	1
2. GENEL BİLGİLER	3
2.1 Dişlerin Embriyolojik Gelişimi.....	3
2.2 Diş erüpsiyonu	6
2.3 Büyüme Gelişimin Belirlenmesi.....	7
2.3.1 Diş Gelişimi ve Yaş Tahmini Yöntemleri.....	9
2.3.1.1 Erişkin bireylerde yaş tayin yöntemleri	10
2.3.1.2 Erişkin olmayan bireylerde yaş tayin yöntemleri.....	11
2.4 Daimi Birinci Büyük Azı Diş.....	16
2.4.1 Daimi birinci büyük azı dişlerin çekim endikasyonları	18
2.4.2 Daimi birinci büyük azı dişlerin çekim zamanı	19
2.4.3 Daimi birinci büyük azı dişlerinin çekim komplikasyonları	25
2.5 Panoramik Radyografi	26
2.5.1 Panoramik radyografi endikasyonları	27
2.5.2 Panoramik radyografi avantajları.....	27
2.5.3 Panoramik radyografi dezavantajları	28
2.6 Yapay Zekâ Nedir?	28
2.6.1 Yapay zekânın tarihsel gelişimi	29
2.6.2 Yapay zekânın amaçları.....	30
2.7 Makine Öğrenmesi.....	31
2.7.1 Danışmalı (öğretmenli) öğrenme	32
2.7.2 Danışmansız (öğretmensiz) öğrenme.....	33
2.7.3 Takviyeli (destekleyici) öğrenme.....	33
2.8 Yapay Sinir Ağları	34

2.8.1 Yapay sinir ağlarının yapısı	36
2.8.1.1 Tek katmanlı algılayıcılar	37
2.8.1.2 Çok katmanlı algılayıcılar	38
2.8.1.3 İleri beslemeli ağlar	38
2.8.1.4 Geri beslemeli ağlar	39
2.8.2 Yapay sinir ağlarının kullanım alanları.....	39
2.9 Derin Öğrenme.....	40
2.10 Evrişimli sinir ağları	41
2.10.1 Evrişimli sinir ağı katmanları.....	42
2.10.1.1 Giriş katmanı (input layer).....	42
2.10.1.2 Evreşim katmanı (convolution layer).....	43
2.10.1.7 Sınıflandırma katmanı (classification layer)	44
2.10.2 Evrişimli sinir ağının eğitilmesi.....	44
2.10.3 Derin öğrenme mimarilerinde hiperparametre kavramı.....	45
2.11 Derin Öğrenme Modelleri.....	45
2.11.1 LeNet.....	45
2.11.2 AlexNet.....	45
2.11.3 ZF Net	46
2.11.4 VGGNet	46
2.11.5 GoogLeNet.....	46
2.11.6 ResNet.....	47
2.11.7 DenseNet.....	47
2.11.8 U-Net.....	47
2.11.9 R-CNN	48
2.11.10 You Only Look Once -YOLO.....	48
2.12 Derin Öğrenme Kütüphaneleri.....	49
2.13 Derin Öğrenmede Görüntü Segmentasyonu	50
2.14 Dış Hekimliğinde Yapay Zekâ Kullanım Alanları.....	51
3. MATERYAL METOD	54
3.1 Görüntülerin seçilmesi	54
3.2 Radyografik veri setlerinin elde edilmesi	55
3.3 Derin Öğrenme Mimarisi	59
3.4 Model Geliştirilmesi	59
3.5 Eğitim Aşaması.....	59
3.5.1 Demirjian Metodu Sınıflandırma Eğitimleri	61

3.6 İstatiksel Analiz	63
3.6.1 Hata Matrisi Hesaplama Prosedürü	64
3.7 Performans Deęerlendirme	64
3.8 Kesinlik- Duyarlılık Eğrisi (PR Eğrisi, Precision-Recall Curve).....	65
4. BULGULAR.....	67
5. TARTIŞMA	76
6. SONUÇLAR.....	86
7. KAYNAKÇA.....	88
8. EKLER.....	99
9. ÖZGEÇMİŞ	100



TABLO LİSTESİ

Tablo 2. 1 Süt dişlerin sürme zamanları [22].	7
Tablo 2. 2 Daimi dişlerin sürme zamanları [22].	7
Tablo 2. 3 Demirjian sınıflaması A-H grupları açıklaması [52].	16
Tablo 2. 4 Zorunlu çekimi gereken dişler için kompenzasyon ve balans çekimleri [2].	24
Tablo 2. 5 Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları [112]. ...	35
Tablo 3. 1 Detection/bonding box ve segmentasyon için veri seti sınıflandırması.	60
Tablo 3. 2 Demirjian metodu diş gelişim safhaları (A-H) veri seti sayıları.	61
Tablo 3. 3 İkili sınıflandırma için karışıklık matrisi.	64
Tablo 4. 1 Detection ve segmentasyon için DP, YP ve YN değerleri.	68
Tablo 4. 2 YOLOv5 modelinin detection ve segmentasyon için duyarlılık, kesinlik ve F1 skorları.	68
Tablo 4. 3 Detection için Kesinlik-Duyarlılık eğrisi sonuçları.	70
Tablo 4. 4 Segmentasyon için Kesinlik-duyarlılık eğrisi sonuçları.	72

ŞEKİL LİSTESİ

Şekil 2. 1 Dişlerin embriyolojik gelişimi [18].	6
Şekil 2. 2 Schour ve Massler metodu [43].	12
Şekil 2. 3 Demirjian sınıflaması A-H grupları görseli [52].	15
Şekil 2. 4 Alt ve üst dişlerinin eksen eğimleri. Çekim sonrası radyografik değerlendirmelerde; alt çenede devrilme hareketi olurken, üst çenede devrilme hareketinin görülmesi daha güçtür [95].	22
Şekil 2. 5 Panoramik radyografi, Planmeca Promax 2D (Planmeca, Helsinki, Finland).	27
Şekil 2. 6 Turing testi [111].	29
Şekil 2. 7 Yapay zekâdan derin öğrenmeye temel kavramlar [115].	31
Şekil 2. 8 Makine öğrenmesi yöntemleri [117].	32
Şekil 2. 9 Sağlık alanında veri çeşidine göre kullanılan makine öğrenmesi yöntemleri [122].	34
Şekil 2. 10 Biyolojik sinir hücresi ve yapay sinir ağı [123].	35
Şekil 2. 11 Yapay sinir hücresinin yapısı [112].	36
Şekil 2. 12 Çok katmanlı yapay sinir ağı şeması [112].	37
Şekil 2. 13 İki girdi ve bir çıktıdan oluşan tek katmanlı bir yapay sinir ağı [116].	37
Şekil 2. 14 Çok katmanlı algılayıcı mimarisi [112].	38
Şekil 2. 15 İleri ve geri beslemeli ağ örnekleri [125].	39
Şekil 2. 16 Yapay zeka uygulama alanları [128].	40
Şekil 2. 17 Makine öğrenmesi ve evrişimli sinir ağlarıyla derin öğrenme [136].	42
Şekil 2. 18 Derin öğrenmede görüntü segmentasyonu [136].	51
Şekil 3. 1 Demirjian safha A.	55
Şekil 3. 2 Demirjian safha B.	56
Şekil 3. 3 Demirjian safha C.	56
Şekil 3. 4 Demirjian safha D.	56
Şekil 3. 5 Demirjian safha E.	56
Şekil 3. 6 Demirjian safha F.	57
Şekil 3. 7 Demirjian safha G.	57
Şekil 3. 8 Demirjian safha H.	57
Şekil 3. 10 Sistem üzerinde bounding box/area detection yöntemiyle etiketleme yapılması.	59
Şekil 3. 11 Veri setleri dağılımı.	60
Şekil 3. 12 Demirjian safha A; detection ve segmentasyonla etiketlenmiş.	61
Şekil 3. 13 Demirjian safha B; detection ve segmentasyonla etiketlenmiş.	62
Şekil 3. 14 Demirjian safha C; detection ve segmentasyonla etiketlenmiş.	62
Şekil 3. 15 Demirjian safha D; detection ve segmentasyonla etiketlenmiş.	62
Şekil 3. 16 Demirjian safha E; detection ve segmentasyonla etiketlenmiş.	62
Şekil 3. 17 Demirjian safha F; detection ve segmentasyonla etiketlenmiş.	63
Şekil 3. 18 Demirjian safha G; detection ve segmentasyonla etiketlenmiş.	63
Şekil 3. 19 Demirjian safha H; detection ve segmentasyonla etiketlenmiş.	63
Şekil 3. 20 Kesinlik-Duyarlılık eğrisi.	66
Şekil 4. 1 YOLOv5 modelinin detection verilerinden elde edilen normalize edilmiş hata matrisi.	69
Şekil 4. 2 YOLOv5 modelinin detection için Kesinlik-Duyarlılık eğrisi.	70

Şekil 4. 3 YOLOv5 modelinin segmentasyon verilerinden elde edilen normalize edilmiş hata matrisi.	71
Şekil 4. 4 YOLOv5 modelinin segmentasyon PR eğrisi (kesinlik-duyarlılık eğrisi, precision-recall curve) ve her bir sınıfa ait AUC değerleri.	71
Şekil 4. 5 Aynı hastaya ait panoramik radyografilerden üstte segmentasyon ile yapılan sınıflama gösterilirken altta ise yapay zekâ modelinin 37 ve 47 numaralı dişler için doğru pozitif tespiti gösterilmiştir.	73
Şekil 4. 6 Aynı hastaya ait panoramik radyografilerden üstteki segmentasyon ile yapılan sınıflama gösterilirken altta ise yapay zekâ modelinin 37 ve 47 numaralı dişler için doğru pozitif tespiti gösterilmiştir.	74
Şekil 4. 7 Aynı hastaya ait panoramik radyografilerden üstte detection ile yapılan etiketleme gösterilirken altta ise yapay zekâ modelinin 37 numaralı diş için yanlış pozitif 47 numaralı diş için doğru pozitif tahmini gösterilmiştir.	75



KISALTMALAR

ark. : Arkadaşları

BT : Bilgisayarlı Tomografi

CNN/ESA : Convolutional Neural Network/Evrişimli Sinir Ağları

DN : Doğru Negatif (True Negative)

DP : Doğru Pozitif (True Positive)

IBM : International Business Machines

IoU : Intersection Over Union

KIBT : Konik Işınlı Bilgisayarlı Tomografi

mAP : Mean Average Precision/Ortalama Kesinlik Değerlerinin Ortalaması

MIH : Ön Keser Diş Hipomineralizasyonu

MIT : Massachusetts Institute of Technology

MS COCO : Microsoft Common Objects in Context

PR : Precision-Recall

R-CNN : Bölge tabanlı CNN

YN : Yanlış Negatif (False Negatif)

YP : Yanlış Pozitif (False Positive)

YOLO : You Only Look Once

DAİMİ DENTİSYONDA MANDİBULAR İKİNCİ MOLAR DIŞLERİN KÖK OLUŞUM SEVİYELERİNİN YAPAY ZEKÂ İLE DEĞERLENDİRİLEREK ÇEKİM ENDİKASYONU OLAN BİRİNCİ MOLAR DIŞLERİN İDEAL ÇEKİM ZAMANININ BELİRLENMESİ

ÖZET

Çocukların büyüme gelişiminde büyük öneme sahip olan daimi birinci büyük azı dişleri en fazla çürük görülen dişlerdir ve genelde buna bağlı olarak sergiledikleri zayıf prognoz nedeniyle erken yaşlarda kaybedilmektedir. Birinci azı dişlerinin çekimi için uygun zamanın tayin edilmesi çocukların fiziksel gelişimi için önemlidir. Dişlerin kalsifikasyon aşamalarını sınıflandıran Demirjian metodunda E safhası daimi birinci büyük azı dişlerinin çekim kararı için ideal bir zamandır ve çocuklarda 8-10 yaş aralığına tekabül eder.

Yapacağımız tez çalışmasında daimi dentisyonda çekim endikasyonu olan mandibular birinci büyük azı dişlerin ideal çekim zamanının belirlenmesinde; mandibular ikinci büyük azı dişlerin Demirjian metoduna göre gelişim safhalarının panoramik radyografiler üzerinden yapay zekâ programına öğretilmesi ve buna bağlı olarak ideal çekim zamanının yapay zekâ uygulaması tarafından belirlenebilirliğini değerlendirilmiştir.

Yapay zekâ teknolojileri gün geçtikçe hayatımızın her alanında yer almaktadır. Bu konuda, diş hekimliği ve özellikle ağız, diş, çene radyolojisi alanlarında hızla yeni gelişmeler yaşanmaktadır. Tez çalışmamızda evrişimli sinir ağları kullanılarak Demirjian metodu kalsifikasyon aşamalarının, yapay zekâ ve derin öğrenmeye dayalı bir modelle otomatik olarak sınıflandırılabilmesi amaçlandı. Bu çalışmada 1106 adet panoramik radyografi üzerinde 37 ve 47 numaralı dişlerin segmentasyon ve detection yöntemleri ile etiketleme yapıldı. Görüntüler üzerinde dişlerin etiketlenmesinde CranioCatch etiketleme yazılımı (CranioCatch, Eskişehir, Türkiye) kullanıldı. Demirjian metodunun A-H' a kadar 8 safhası için 8 adet veri seti oluşturuldu. YOLOv5 modeli kullanılarak eğitildi. Detection yönteminde yaklaşık olarak 0,990 duyarlılık, 0,917 kesinlik ve 0,952 F1 skoruna sahip sonuçlar elde edilirken, segmentasyon yönteminde 0,985 duyarlılık, 0,921 kesinlik, 0,952 F1 skoru sonuçları elde edildi.

Çalışmamızın sonuçlarına göre geliştirilen derin öğrenme modellerinin; daimi birinci büyük azı dişlerin ideal çekim zamanını belirlemek için kullandığımız Demirjian metodunun safhalarını tespit/tahmin etmedeki başarılı olduğu görülmüştür. Zaman içerisinde yapılacak çalışmalarla birlikte, derin öğrenmeye dayalı yapay zekâ uygulamaları klinik pratiğinde yer alabileceği ve hekimlere destek olabileceği düşünülmektedir.

Anahtar kelimeler: Yapay zekâ, derin öğrenme, YOLOv5, daimi birinci molar diş, Demirjian metodu



IN PERMANENT DENTITION DETERMINATION THE IDEAL EXTRACTION TIME OF FIRST MOLAR TEETH BY EVALUATION OF ROOT FORMATION LEVELS OF MANDIBULAR SECOND MOLARS WITH ARTIFICIAL INTELLIGENCE

SUMMARY

Permanent first molars, which are of great importance in the growth development of children, are the most carious teeth and are usually lost at an early age due to their poor prognosis. Determining the appropriate time for extraction of first molars is important for the physical development of children. In the Demirjian method, which classifies the calcification stages of teeth, stage E is the ideal time for the decision to extract permanent first molars and corresponds to the age range of 8-10 years in children.

In our thesis study, in determining the ideal extraction time of mandibular first molars, which are indicated for extraction in permanent dentition, the developmental stages of mandibular second molars according to the Demirjian method are taught to the artificial intelligence program through panoramic radiographs and accordingly, the ideal extraction time can be determined by the artificial intelligence application.

Artificial intelligence technologies are taking place in every aspect of our lives day by day. In this regard, new developments are rapidly taking place in dentistry and especially in the fields of oral, dental and maxillofacial radiology. In our thesis study, it was aimed to automatically classify the calcification stages of Demirjian method using convolutional neural networks with a model based on artificial intelligence and deep learning. In this study, teeth numbered 37 and 47 were labeled with segmentation and detection methods on 1106 panoramic radiographs. CranioCatch labeling software (CranioCatch, Eskişehir, Turkey) was used to label the teeth on the images. Eight datasets were created for the 8 stages of the Demirjian method from A to H. It was trained using the YOLOv5 model. The detection method yielded results with approximately 0.990 sensitivity, 0.917 precision and 0.952 F1 score, while the

segmentation method yielded results with 0.985 sensitivity, 0.921 precision and 0.952 F1 score..

According to the results of our study, the developed deep learning models were found to be successful in detecting/predicting the stages of the Demirjian method, which we used to determine the ideal extraction time of permanent first molars. With the studies to be conducted over time, it is thought that artificial intelligence applications based on deep learning can take place in clinical practice and support physicians.

Keywords: Artificial intelligence, deep learning, YOLOv5, permanent first molar, Demirjian method



1. GİRİŞ VE AMAÇ

Ağız ortamına ilk süren dişler daimi birinci büyük azı dişlerdir. Bu dişlerin sürmesi ile erken çocukluk çağı dönemi sonlanır ve karışık dişlenme dönemi başlar. Aynı zamanda daimi dentisyonda çeşitli sebeplerden dolayı en fazla çürük görülen dişler birinci büyük azı dişleridir ve genelde buna bağlı olarak sergiledikleri zayıf prognoz nedeniyle erken yaşlarda kaybedilmektedir. Ancak daimi birinci büyük azı dişleri büyük öneme sahiptir. Çocukların büyüme gelişimi ve sindirim sistemleri üzerinde önemli rolleri vardır. Vertikal yüz yüksekliğinin, oklüzyon ve çiğneme fonksiyonunun temelini oluştururlar [1]. Beslenme alışkanlıkları, oral hijyen yetersizliği, sistemik hastalıklar, çevresel faktörler ve/veya gelişimsel defektler gibi etiyolojik faktörlerin olumsuz etkileri nedeniyle kötü prognoza sahip daimi birinci büyük azı dişlerin çekim zamanı doğru bir şekilde tespit edilmelidir. Oklüzyonun anahtarı olarak görülen bu dişlerin çekimi kontrolsüz yapıldığında dental arktaki diğer dişlerin boşluğa doğru devrilmelerine ya da yer değiştirmelerine bazen de uzamalarına neden olabilmektedir. Doğru zamanda yapılan çekim planlamasıyla ikinci büyük azı ve takiben üçüncü büyük azı dişlerinin çekim boşluğuna doğru mezial yönde paralel hareket etmesi sonucu uygun bir oklüzal ilişki elde etmenin mümkün olacağı belirtilmektedir. İdeal olarak ikinci büyük azı dişinin çekim boşluğuna paralel hareket edebilmesi için hastanın yaşının 8 ila 10 arasında olması gerekli görülmektedir. Radyografik olarak bu dönem ikinci büyük azı dişinin bifurkasyon bölgesi henüz mineralizasyon aşamasındayken yani kuron formasyonunun tamamlanıp kök oluşumunun 1/3'lük bölümünün bitmek üzere olduğu zamandır. Bu dönem dişlerin kalsifikasyon aşamalarını sınıflandıran ve ülkemizde sıkça kullanılan Demirjian metodunda E safhasına denk gelmektedir [2].

Diş hekimliğinde radyolojik görüntülemelerle destekli yapılan muayeneler; tanı, tedavi planlaması ve hasta takibi açısından oldukça önemlidir. Panoramik radyografilerin daimi birinci büyük azı dişlerin kalsifikasyon aşamalarını izleme imkanı sağlamanın yanı sıra maksillo-mandibular kompleksi, tüm dento-alveolar bölge ve komşu yapıları değerlendirmede standart olduğu gösterilmiştir [3].

Yapay zekâ son yıllarda birçok alanda kullanıldığı gibi diş hekimliğinde özellikle radyoloji alanında sıkça kullanılmaya başlamıştır. Çürük tespiti, periodontal lezyonların varlığı, mandibular kanal seyrinin belirlenmesi, kistlerin ve tümörlerin tespiti ve daha bir çok çalışmada yapay zekâ sistemleri kullanılmıştır [4].

Yapay zekâ, bir makinenin problem çözme, nesne ve kelime tanıma ve karar verme gibi insanların bilişsel işlevlerini taklit eden karmaşık görevleri yerine getirme yeteneği olarak tanımlanmaktadır. Makine öğrenimi, bilgisayarların veri birikimiyle otomatik olarak öğrendiği bir yapay zekâ alanı olarak tanımlanır. Makine öğrenimi ile bir bilgisayarın kapsamlı bir veri tabanından bir sonucu sınıflandırması veya tahmin etmesi mümkündür. Verilere daha fazla maruz kaldıkça makine öğrenimi algoritmaları geliştirilir; sadece kurallara bağlı kalmazlar, deneyimle gelişirler, büyük miktarda veriyi değerlendirerek belirli cevaplar vermeyi öğrenirler. Derin öğrenme, makine öğreniminin bir alt kümesidir ve görüntü yorumlama için çoğu yapay zekâ aracının temelini oluşturur. Yapay sinir ağları, insan nöronlarından ilham alarak bilgisayar programları aracılığıyla oluşturulan matematiksel modellerdir. Evrişimli Sinir Ağları (ESA/CNN) olarak adlandırılan derin öğrenme yapıları, çoklu katmanlardan oluşur ve özellikle büyük ve karmaşık görüntüleri işlemek için kullanılır [5].

Bu tez çalışmasında daimi dentisyonda çekim endikasyonu olan mandibular 1. büyük azı dişlerin ideal çekim zamanının belirlenmesinde; mandibular 2. büyük azı dişlerin Demirjian metoduna göre gelişim safhalarının panoramik radyografiler üzerinden yapay zekâ sistemine öğretilmesi ve buna bağlı olarak ideal çekim zamanının yapay zekâ uygulaması tarafından belirlenebilirliği değerlendirilmesi planlanmıştır.

2. GENEL BİLGİLER

2.1 Dişlerin Embriyolojik Gelişimi

İnsanlarda diş gelişimi, embriyo henüz 6 haftalıkken başlar. Dişin embriyonik gelişimi; ektoderm ve mezoderm arasındaki epitel ile nöral krest kaynaklı mezenkim arasında ardarda gerçekleşen karşılıklı indükleyici sinyaller sonucu oluşur [6, 7]. Mine, oral kavitenin ektoderminden kaynaklanırken dişin diğer tüm yapıları ise ektodermal epitelin altındaki mezenkimden farklanır [6]. Baş ve boyundaki nöral krest hücreleri mezenkim hücreleri ile benzerlik gösterir. Bu hücreler epitel hücreleri ile birlikte dişlerin ve tükürük bezlerinin gelişimine katılırlar, aynı zamanda yüzün kemik, kıkırdak, sinir ve kaslarının oluşumunda da rol oynarlar [8]. Ektodermin vestibülünde bulunan lamina vestibüler lamina, lingual veya palatinalinde bulunan lamina ise dental lamina adı verilmektedir. Dental laminadan dişler gelişirken, vestibüler laminadan dişeti ve vestibüler sulkus gelişmektedir [9]. Bütün dişlerin gelişimi aynı zaman diliminde gerçekleşmez. İlk diş tomurcukları anterior mandibular bölgede belirir ve anterior maksiller bölgede devam eder. Daha sonra her iki çenede de arkaya doğru ilerler. Dental lamina üzerinde süt dişlerinin gelişeceği 20 alan oluşur. Daimi dişlerin gelişeceği dental laminanın lingual uzantısına da daimi diş laminası denir. Böylece dental lamina; prenatal 6. haftadan başlayarak doğumdan sonra 15. yıla kadar toplam 52 dişin gelişiminden sorumludur [10-12].

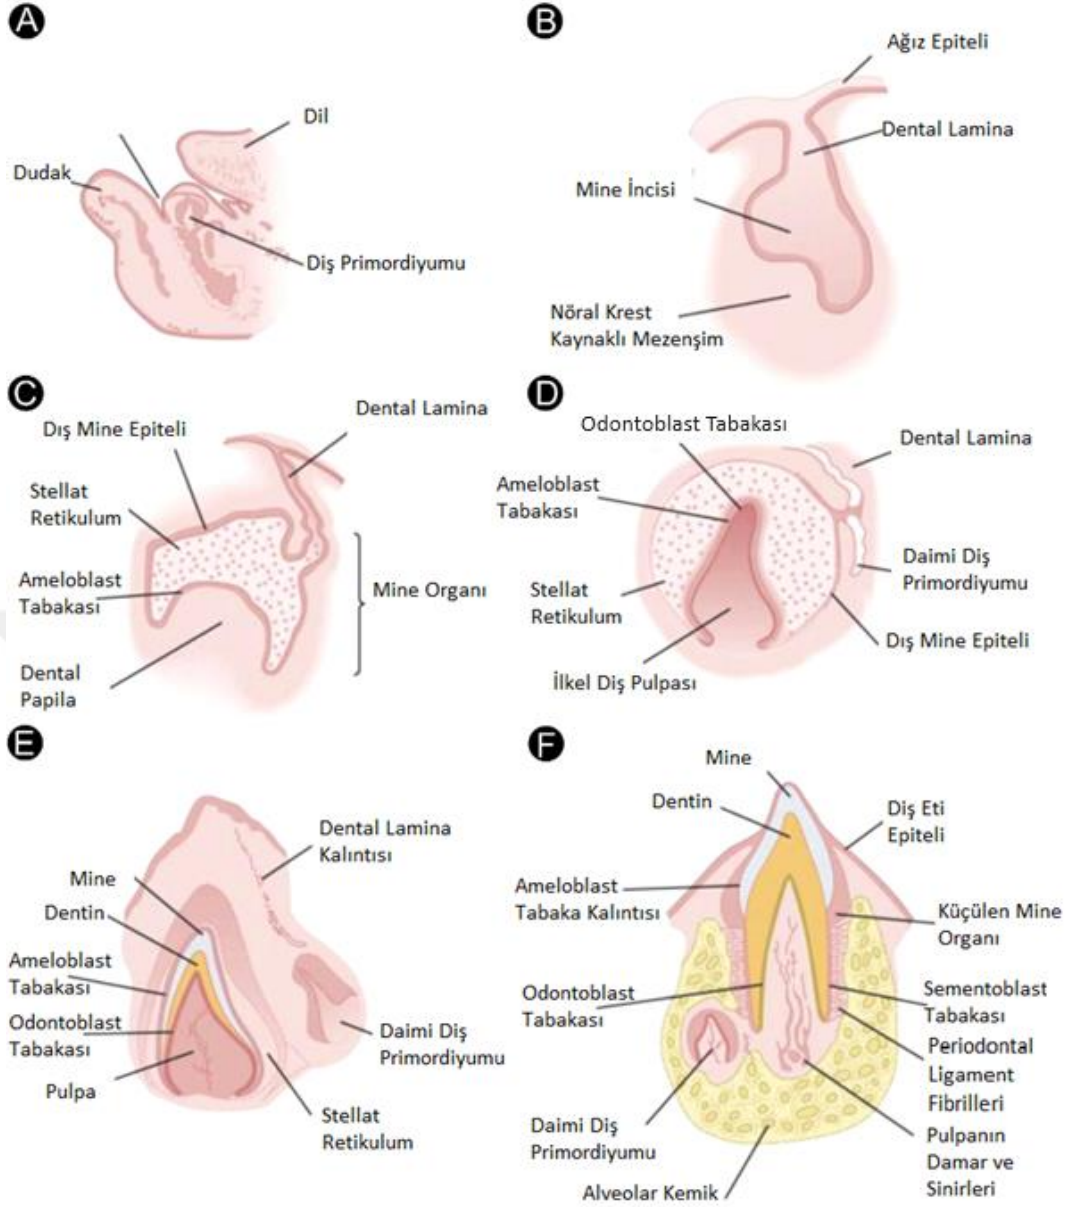
Diş gelişimi; birçok faktörün etkileşimini gerektiren ve devamlılık gösteren kompleks bir süreçtir. Kolay anlaşılması amacı ile değişik evrelere ayrılmıştır; ancak birbiri ile ilişkili olan bu evreleri kesin sınırlar ile ayırmak oldukça zordur ve birçok kaynakta değişik sınıflamalar bulunmaktadır [7, 10].

Diş gelişiminin ilk morfolojik belirtisi; ağız epitelyumunun kalınlaşmasıdır. Nöral krest hücreleri epitel hücrelerini indükler ve ağız epitel hücrelerinin proliferasyonu sağlar. Bunun sonucunda dental lamina gelişir bu daha sonra alttaki mezenkime tomurcuklanır. Mezenkimal hücreler tomurcuğun etrafında yoğunlaşır ve epitel dokusunun hızlı bir şekilde büyümesi ve katlanmasının ardından kep aşamasına ulaşılır. Bu aşamada hücre çoğalması, epitelyal tomurcuğun ekvator bölgesinde hızlı,

kutup bölgesinde ise daha yavaş gerçekleşir. Bu farklı hücre çoğalma hızları sonucunda oluşan yapı kep şeklini almaktadır [6, 9, 13]. Bu sırada, epitel tomurcuklarının uç kısımlarında, mine düğümü olarak isimlendirilen bölünmemiş hücreler meydana gelmektedir. Mine düğümü; sentezlediği çok sayıda sinyal verici moleküller ile tüberküllerin formasyonunda ve çevre dokuların gelişiminde kontrol merkezi olarak işlev görür [14]. Mezenkim tabakasının iç tabakası daha yoğundur ve bu yoğunlaşmış mezenkim tabakasından dental papilla oluşurken, daha az yoğun dış tabakasından dental folikül oluşmaktadır [9]. Dental folikül aracılığıyla, sementi oluşturan sementoblastların ve diş kökünü alveol kemiğe bağlayan periodontal ligamentin oluşumu gerçekleşir. Bu aşamada, yoğunlaşmış epitel hücrelerinden oluşan kep şeklindeki yapıya, mine organı adı verilmektedir. Dışta bulunan kübik epitel hücreleri dış mine epitelini oluştururken, içteki silindirik epitel hücreleri ise iç mine epitelini oluşturmaktadır. Kep şeklindeki yapının ortasında bulunan epitel hücreleri arasında, hücreler arası boşluk giderek genişlemekte ve bu bölge, dişin pulpa dokusuna benzemesi nedeniyle, mine pulpası (stellat retikulum) olarak isimlendirilmektedir. Embriyonik gelişimin 12. ve 13. haftasında mine organının kep biçimi derinleşerek çan şeklini alır ve bu evre çan evresi olarak isimlendirilir. Bu evrede tüberküllerin ve diş kronunun şekli belirlenmektedir. Epitelyal kökenli ameloblast hücreleri ve mezenşimal kökenli odontoblast hücrelerinin farklılaşması ile mine ve dentin birikimi başlar. İlk olarak odontoblastlar predentin matriksini üretir. Daha sonra dentin ve ardından mine matriksinin, ilk önce dişlerin kesici kenarları veya tüberkül tepeleri şekillenecek biçimde, birbirleri üzerinde salgılanması ile kuron şekli belirlenir ve mineralizasyon, dişlerin kesici kenarları ve tüberkül tepelerinden başlayıp köke doğru ilerler. Bu süreç yavaş ve kademeli şekilde ilerleyen bir süreçtir [9, 14, 15]. Mineral tuzlarının çökmesi ile oluşan matriksin sertleşmesine kalsifikasyon adı verilir [16]. Diş kökü, kuron oluşumu tamamlandıktan sonra gelişmeye başlar [10]. Bu sırada; hücre çoğalması servikal bölgede ya da mine organı tabanında devam eder, stellat retikulum kaybolur ve iç mine epiteli ile dış mine epiteli birleşir. Bu alana “servikal loop” denir. Servikal looptaki hücreler büyümeye devam ederek; Hertwig epitel kök kını olarak adlandırılan 2 katlı hücre tabakasının gelişmesine neden olur. Bu doku, diş kökünün gelişiminden ve diş sürmesinden sorumludur. Hertwig epitelyal kök kını, tek köklü dişlerde, konik bir şekilde, apeks yönüne doğru ilerlerken; çok köklü dişlerde, hem bifurkasyon/trifurkasyon hem de apeks yönüne doğru ilerler. Dental papilla

aracılıđıyla, olacak kk sayısı kadar Hertwig epitelyal kk kını oluřturulur [9, 17]. Kk bymesi Hertwig epitelyal kk kını ve diř mezenkimi arasındaki etkileřimler tarafından dzenlenir. Kk geliřiminde i taraftaki hcreler odontoblastlara farklılařarak kk dentininin oluřumunu sađlarken; folikler blgedeki mezenkimal hcreler de sementoblastlara farklılařarak sementoid denilen kalsifiye olmamiř sementi salgılamaktadır. Kk blgesinde geriye kalan dental folikl hcreleri de periodontal ligamenti oluřturmaktadır. Sement, mine sınırından itibaren kk dentini zerinde ara ara paralanan Hertwig epitelyal kk kını yerine depolanır. Paralanan Hertwig epitelyal kk kını, Malessez epitel artıklarını oluřturur ve kk yzeyinde bir ađ olarak kalır. Yeterli kk geliřiminin tamamlanmasının ardından diřlerin erpsiyonu bařlar [9, 14, 15].

zetle; mine organı, dental papilla ve dental folikl ile birlikte diř germini oluřturur. Mine organından mine, dental papilladan pulpa ve dentin, dental foliklden sement, periodontal ligament ve alveol kemiđi oluřacaktır [14].



Şekil 2. 1 Dişlerin embriyolojik gelişimi [18].

2.2 Diş Erüpsiyonu

Dişin çene kemiğinde bulunduğu alandan, fonksiyon göreceği ağız boşluğundaki konumuna gelinceye kadar geçen zaman dilimi diş sürmesi olarak adlandırılır [19]. Karşılığı olmayan dişlerde daha belirgin şekilde olmakla birlikte diş sürmesi hayat boyu devam eden bir süreçtir. Erişkin yaşa gelene kadar alveolün ve çenelerin sürekli büyümesi ile ilişkili olarak dişler dikey, mezial ve transversal yönde harekete devam ederler ve alveol kemiğinin büyümesini de indüklerler [16, 20, 21].

Tablo 2. 1 Süt dişlerin sürme zamanları [22].

Diş	Kalsifikasyon başlangıcı		Kron Tamamlanması		Sürme		Kökün Tamamlanması	
	Maksiller	Mandibular	Maksiller	Mandibular	Maksiller	Mandibular	Maksiller	Mandibular
Santral	İntrauterin 14. Hafta	İntrauterin 14. Hafta	1,5 ay	2,5 ay	10 ay	8 ay	1,5 yaş	1,5 yaş
Lateral	İntrauterin 16. Hafta	İntrauterin 16. Hafta	2,5 yaş	3 ay	11 ay	13 ay	2 yaş	1,5 yaş
Kanin	İntrauterin 17. Hafta	İntrauterin 17. Hafta	9 ay	9 ay	19 ay	20 ay	3,75 yaş	3,75 yaş
1.Molar	İntrauterin 15. Hafta	İntrauterin 15. Hafta	6 ay	5,5 ay	16 ay	16 ay	2,5 yaş	2,75 yaş
2.Molar	İntrauterin 19. Hafta	İntrauterin 18. Hafta	11 ay	10 ay	29 ay	27 ay	3 yaş	3 yaş

Tablo 2. 2 Daimi dişlerin sürme zamanları [22].

Diş	Kalsifikasyon Başlangıcı		Kron Tamamlanması		Sürme		Kökün Tamamlanması	
	Maksiller	Mandibular	Maksiller	Mandibular	Maksiller	Mandibular	Maksiller	Mandibular
Santral	3 ay	3 ay	4,5 ay	3,5 ay	7,25 yaş	6,25 yaş	10,5 yaş	9,5 yaş
Lateral	11 ay	3 ay	5,5 yaş	4 yaş	8,25 yaş	7,5 yaş	11 yaş	10 yaş
Kanin	4 ay	4 ay	6 yaş	5,25 yaş	11,5 yaş	10,5 yaş	13,5 yaş	12,25 yaş
1.Premolar	20 ay	22 ay	7 yaş	6,25 yaş	10,25 yaş	10,5 yaş	13,5 yaş	13,5 yaş
2.Premolar	27 ay	28 ay	7,25 yaş	7,5 yaş	11 yaş	11,25 yaş	14,5 yaş	15 yaş
1.Molar	İntrauterin 32. hafta	İntrauterin 32. hafta	4,25 yaş	3,75 yaş	6,25 yaş	6 yaş	10,5 yaş	10,5 yaş
2.Molar	27 ay	27 ay	7,75 yaş	7,5 yaş	12 yaş	12 yaş	15,25 yaş	16 yaş
3.Molar	8 yaş	9 yaş	14 yaş	14 yaş	20 yaş	20 yaş	22 yaş	22 yaş

Diş gelişimi ve dentisyon; adli olaylar ve 20 yaşından küçük bireylerin yaş tespitinde ayrıca önem kazanmıştır. Fakat diş gelişimi ve sürme evreleri, kişilerin genel büyüme ve gelişmesinde olduğu gibi toplumlar arasında genetik yapı ve çevresel faktörlerin değişiminden etkilenir.

2.3 Büyüme Gelişimin Belirlenmesi

Büyüme gelişimin belirlenmesi ve yaş tespiti; antropoloji, adli tıp, pediatri, ortopedi ve diş hekimliğinde gerek duyulan bir incelemedir. Özellikle adli tıpta kimliği

bilinmeyen ve yaşı ile ilgili şüphe duyulan olgularda, gerek canlıda gerekse ölüde, ceza ve medeni hukuk bakımından önem arz etmektedir [23, 24].

Yaş tespitinde kullanılan yöntemler 4 grupta toplanmaktadır. Bunlar radyolojik, morfolojik, histolojik ve biyokimyasal yöntemler olup en sık olarak radyolojik ve morfolojik yöntemler kullanılmaktadır. Bu yöntemlerde boy, ağırlık, puberte belirtileri, ruhsal ve mental gelişim, dişler ve kemik gelişimi gibi kriterler ele alınabilir [23-25].

Günümüz bilgisayar teknolojilerinde görülen hızlı ve büyük gelişmeler tanı için oldukça önemli olan radyolojik sistemlerin hem gelişmesini sağlamış hem de yeni görüntüleme tekniklerinin oluşmasına neden olmuştur. Bu radyolojik görüntüleme teknikleri kişilerin büyüme ve gelişim potansiyelinin saptanması ve iskeletsel gelişim dönemlerinin belirlenmesini sağlar. Bunun için vücudun değişik bölgelerindeki çok sayıda kemikleşme bölgesinden veya dişlerin görünümünden yararlanılabilir. Büyüme esnasında insan vücudundaki her kemik radyolojik olarak görülebilir bir dizi değişiklik geçirir. Bu değişim dizisi bireyler arasında fizyolojik olarak farklılık göstermez ancak zamanlaması bireylerin biyolojik dönemlerine göre farklılık gösterebilir [23, 26].

Radyolojik yöntemde kemiklerin epifiz hatları ve dişlerin görünümünden faydalanılmaktadır. Diş ve kemik gelişimi değerlendirmesi en sık kullanılan yöntemler olmasına rağmen erişkin olmayan bireylerde daha doğru sonuçlar verirler. Kemiklerin epifiz ve metafiz gelişim süreleri, füzyonun ve kaynaşmanın tamamlanması dönemlere göre değişiklik göstermektedir. Bu parametrelere dikkat edildiğinde 22 yaşa kadar yaklaşık bir tespit yapılabilir. Ancak ileri yaşlar için özellikle 25-40 yaş arası olgularda yaş tespitinin yapılması zordur [23].

Her bireyin bir biyolojik bir de kronolojik yaşı vardır. Kronolojik yaş doğumumuzdan itibaren geçen yıl, ay ve günle alakalı iken, biyolojik yaş vücudumuzun fizyolojik durumunun kemiklerimize yansması ile ilgilidir [27].

Kronolojik yaş; takvim yaşı olarak da tanımlayabileceğimiz bu yaş; organizmanın veya bireyin doğumdan sonra hayatta kaldığı süre olarak tanımlanır [26, 28].

Büyüme ve gelişim genetik, epigenetik, çevresel faktörler, beslenme durumu ve hormonal faktörlerden etkilendiği için bireylerin olgunlaşma durumu/büyüme gelişimi incelenirken kronolojik yaş güvenli bir kriter değildir [28]. Bu nedenle, daha doğru bir

ölçüm için somatik, cinsel, diş ve iskelet gelişiminin değerlendirmesine dayanan "biyolojik yaş" esas alınır [29].

Büyüme paterni ile en yakın ilişkili olan biyolojik yaş, iskeletsel yaştır. El bilek grafileri, iskelet gelişiminin ardışık aşamalarının incelenmesini sağlamasıyla en çok kullanılan ve standardize edilmiş iskelet yaşı değerlendirme yöntemlerinden biridir [28]. Bir diğeri ise sefalometrik grafler yardımıyla servikal vertebraların değerlendirilmesidir [26]. Dental yaş da, iskeletsel maturasyonun potansiyel bir belirleyicisi olarak yaygın bir şekilde kullanılmaktadır [28].

2.3.1 Diş gelişimi ve yaş tahmini yöntemleri

Dişler, kimliklendirme çalışmalarında ağırlıklı olarak yaşın belirlenmesi için kullanılmıştır. Dişlerin sert yapıları, düşük metabolizmaları, mekanik kimyasal ve fiziksel etkilere karşı son derece dirençli olmaları ve uzun süre morfolojik yapılarını korumaları kimliklendirme çalışmaları ve yaş tayininde kullanılmasında avantaj sağlamıştır [24, 25]. Dişlerden yaş tahmininde en uygun zaman dişlerin gelişimi sırasında olduğu kabul edilmekte olup, bu süreç güçlü genetik etkiler altında olduğundan çevresel faktörlerden az etkilenir [30]. 11 Eylül 2001 saldırıları ve Asya tsunamisinde hayatını kaybedenlerin büyük çoğunluğunun kimliğinin dental kayıtlar yardımıyla tespit edilmiş olması bunun en çarpıcı örnekleridir [31].

Adli bilimlerin alt disiplini olan yaş tayini, ortodonti ve pediatrik diş hekimliğinde tedavi planlaması açısından önemli olup pediatri ve endokrinoloji gibi tıbbi ve paramedikal alanlarla da ilgilidir [28].

Dental yaş; dişlerin erüpsiyonu, süt dişlerinin değişmesi ya da dişlerin gelişim aşamaları incelenerek değerlendirilebilir ancak dental yaşın belirlenmesinde dişlerin kalsifikasyon aşamaları daha güvenilir kriterler sunduğundan değerlendirmede tercih edilir [28].

Biyokimyasal ve histolojik analizleri içeren dental yaş tayini yöntemleri dişlerin çekimini ve kesitsel olarak çalışılmasını gerektirmektedir. Ancak bu yöntemler, etik olarak kabul edilemez ve özellikle yaşayan bireylerde kullanılamaz. Morfolojik değerlendirme diş mineralizasyonunun gelişimsel aşamalarının incelenmesini içerirken radyografik teknikler ise diş gelişimini ve mineralizasyonunu değerlendirmek için görüntüleme teknolojilerinden yararlanır. Dolayısıyla radyolojik

yaş tayini yöntemleri, canlı ve ölü bireylerde ya da doku toplamının yasak olduğu bazı adli durumlarda kullanılabilen, doğru sonuçlar veren ve invaziv olmayan önemli bir alternatiftir [32-36]. Yapılan çalışmalarda, dental radyograflardan yararlanılarak yaş ve cinsiyetin güvenilir bir şekilde tahmin edildiği bildirilmektedir [37]. Mevcut diğer tekniklerin aksine dental radyograflardan yapılan yaş tespiti, materyalin bütünlüğüne zarar vermeyen bir yöntem olması ve yaşayan bireylerde dişler üzerinde araştırma yapılmasını sağlaması önemli avantaj sağlar [16].

Dişler kullanılarak yapılan yaş tayini genel olarak; çocuklarda geçici ve sürekli dişlerin gelişim aşamalarının ve sürme zamanlarının; erişkinlerde ise sürekli dişlerde meydana gelen morfolojik ve biyokimyasal değişimlerin incelenmesi ile iki ana döneme ayrılarak yapılmaktadır [25].

2.3.1.1 Erişkin bireylerde yaş tayin yöntemleri

Dişlerde görülen yaşa bağlı değişikliklerin yetişkinlerde yaş tayin yöntemi olarak kullanılabileceği ilk kez Gustafson[38] tarafından gösterilmiştir [39]. Yetişkinlerde dentisyonun gelişimi tamamlanmış olmasından dolayı dişlerde ve çevre dokularda yaşa bağlı ortaya çıkan değişikliklerin incelenmesi ile farklı yöntemler geliştirilmiştir [31, 38].

- **Gustafson yöntemi(1950)**
- **Bang and Ramm (1970)**
- **Johanson sectioning (1971)**
- **Maples (1978)**
- **Harris ve Nortjé yöntemi (1984)**
- **Van Heerden sistemi (1985)**
- **Kvaal'in pulpa-diş oranı yöntemi (1995)**
- **Prince and Ubelaker (2002)**
- **Cameriere yöntemi (2004)**
- **Kuronal pulpa kavite indeksi (2008)**

Bu yöntemler; kök transparanlığı, sement apozisyonu, atrizyon, aspartik asit rasemizasyonu, kök rezorpsiyonu, diş renginin koyulaşması, dişeti çekilmesi, sekonder dentin apozisyonu, telomer kısalması, radyoaktif karbon 14 gibi parametreleri içeren yöntemlerdir [25]. Ancak yaş tayini yapılırken kullanılacak

dişlerin bozulmamış ve eksiksiz olması gerekir [39]. Fakat yetişkinlerde dişlerden yararlanılarak yapılan yaş tayini; beslenme, fiziksel koşullar, hastalıklar gibi birçok endojen ve eksojen faktöre de bağlıdır [40].

2.3.1.2 Erişkin olmayan bireylerde yaş tayin yöntemleri

Bu dönemdeki yaş tayini yöntemleri; diş germelerinin görünüşü, dişlerin mineralizasyonu, mine formasyon oranı, sürmüş diş köklerinin tamamlanma dereceleri, erüpsiyon süreçleri ve inkremental çizgilerin miktarı gibi yöntemleri içerir. Farklı araştırmacılar tarafından kullanılan bu yöntemler bulucularının isimleri ile anılmıştır ve en çok bilinenleri de aşağıdaki gibidir: [25]:

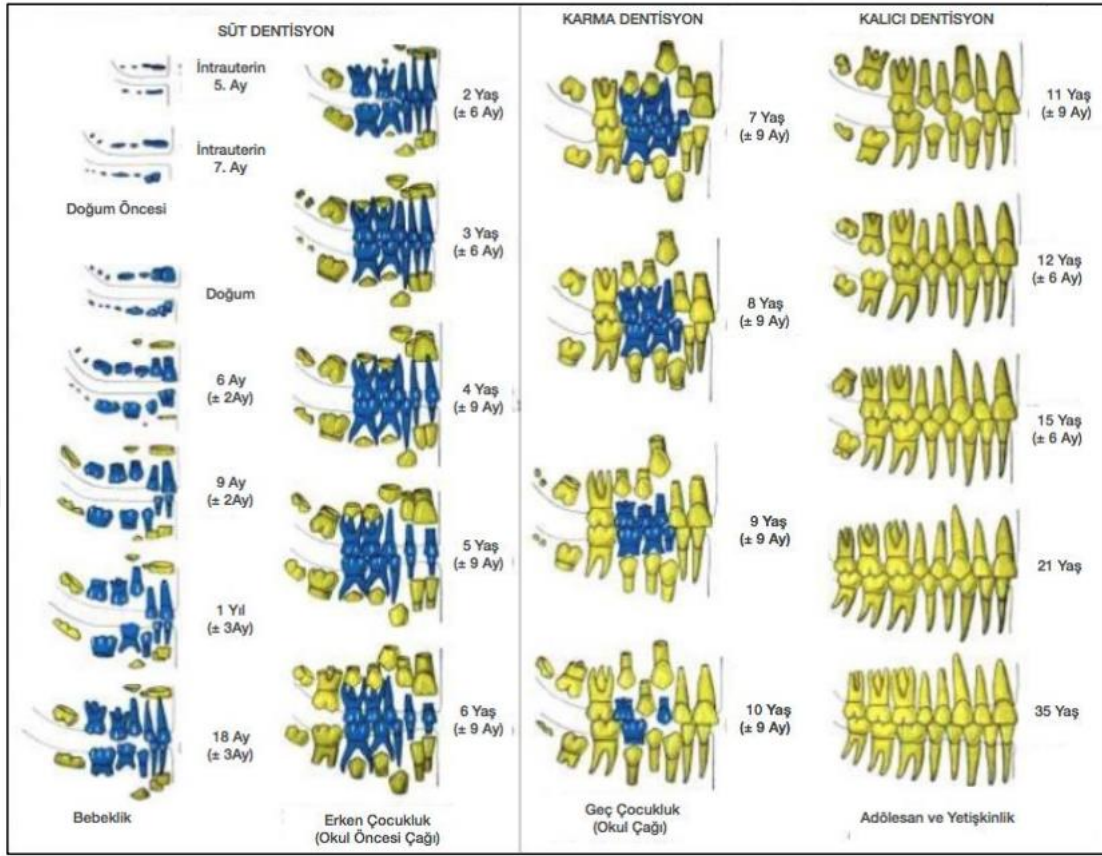
- **Logan ve Kronfeld metodu (1933)**
- **Schour ve Massler metodu (1941)**
- **Gleiser ve Hunt metodu (1955)**
- **Nolla metodu (1960)**
- **Moorrees ve ark. metodu (1963)**
- **Anderson ve ark. metodu (1973)**
- **Demirjian, Goldstein ve Tanner metodu (1973)**
- **Nyström ve ark. metodu (2000)**

Bir bireyin yaşının tahmini için dişlerin kullanılmasına dair ilk çalışma 1837 yılında Saunders tarafından yapılmıştır. Saunders; bir fabrikada, izinsiz olarak çalıştırılan dokuz yaş altı çocukların ve dokuz saatten fazla çalıştırılan dokuz ila on üç yaş arasındaki çocukların yaş tahminini veren bir tablo yayınlamıştır [41].

Logan ve Kronfeld [42]'in 1933'teki çalışması dişlerin gelişim aşamalarını ortaya koyan ilk çalışmalardan biri olması açısından önemlidir. 25 adet taze postmortem örnek üzerinde değerlendirmelerini yapmışlardır. Dişlerin radyografilerini çekmişler ve daha sonra seri halinde histolojik kesitlerini hazırlamışlardır. Bu çalışmada özellikle, yeni doğanlarda diş gelişim sırası ve dişler arasındaki gelişim farkları ortaya konulmuştur. Bu yöntem ilk olması açısından önemliydi, fakat hasta bireylere ait çok az örnek üzerinde çalışılması dezavantajdı [42].

Schour ve Massler [43]'in 1941'de oluşturdukları metod dental yaş tayin yöntemlerinin arasında ilk atlas metodudur. her bir yaşta beklenen dental gelişim

evrelerinin maksilla ve mandibula radyografilerinin karşılaştırmalı diyagramlarını içermektedir (Şekil 2.2).



Şekil 2. 2 Schour ve Massler metodu [43].

Glesier ve Hunt [44] ise 1955 yılında yaptıkları çalışmada alt çenede birinci azı dişlerinin kalsifikasyon aşamalarını radyograflara dayanarak detaylı bir şekilde ilk kez tanımlamışlardır [45].

Nolla [46] 1960 yılında yaptığı çalışmada; tüm daimi dişleri, germlerin oluşumundan apeksogenezisin tamamlanmasına kadar 10 ayrı evrede değerlendirilerek skorlamıştır. Daha sonra, 7 mandibular ve 7 maksiller dişin skorlarının toplanmasıyla elde edilen toplam diş gelişim skoruna göre kızlar ve erkekler için ayrı olmak üzere tablolar hazırlamıştır [46].

Moorrees ve ark.[47]'nin 1963 yılında iskelet kalıntılarını kimliklendirilmesi amacıyla yaptığı çalışmada, tek ve çok köklü daimi dişlerin gelişimi panoramik ve lateral oblik radyograflar kullanılarak değerlendirilmiştir. Diş gelişimi daimi dişlerin tüberkül tepesi oluşumunun görüldüğü safhadan, apeksogenezisin tamamlandığı

safhaya kadar 14 farklı gelişim evresinde incelenmiş olup, kız ve erkek çocuklar için farklı tablolar oluşturulmuştur. Dişler gelişim aşamalarına göre tablodaki uygun yerlere yerleştirilerek yaş tayini yapılmıştır [47].

Moorrees ve ark.[47]'dan farklı olarak Anderson ve ark.[48] 1973'te 14 aşamanın her evresindeki ortalama yaşı ve standart sapmalarını hesaplamışlardır. Hem alt hem de üst çene dişleri için her safhanın ortalama yaşı ve standart sapması kadınlar ve erkekler için ayrı ayrı olmak üzere yayınlanmıştır. Ayrıca 3. molar dişler de dahil olmak üzere tüm diş dizisi değerlendirilmiştir [48].

Nyström ve ark.[49]'nın metodu dişlerin sürme periyotlarının değerlendirilmesinin uygun ve basit bir yaş tayini yöntemi olduğunu kabul eder ve diş sürmesinin daha çok genetik açıdan kontrol edilmesinden dolayı sadece erüpsiyonu doğum sonrası 6. ayda başlayan ve yaklaşık 2,5 yaş civarında sona eren süt dişlerinde kullanılmaktadır. Ağız-içi şartlar, enfeksiyon, erken diş kaybı ve ark boyutu gibi etkenlere maruz kalmasından dolayı daimi dişlerin bu yöntemle değerlendirilmesi uygun bulunmamıştır [49, 50].

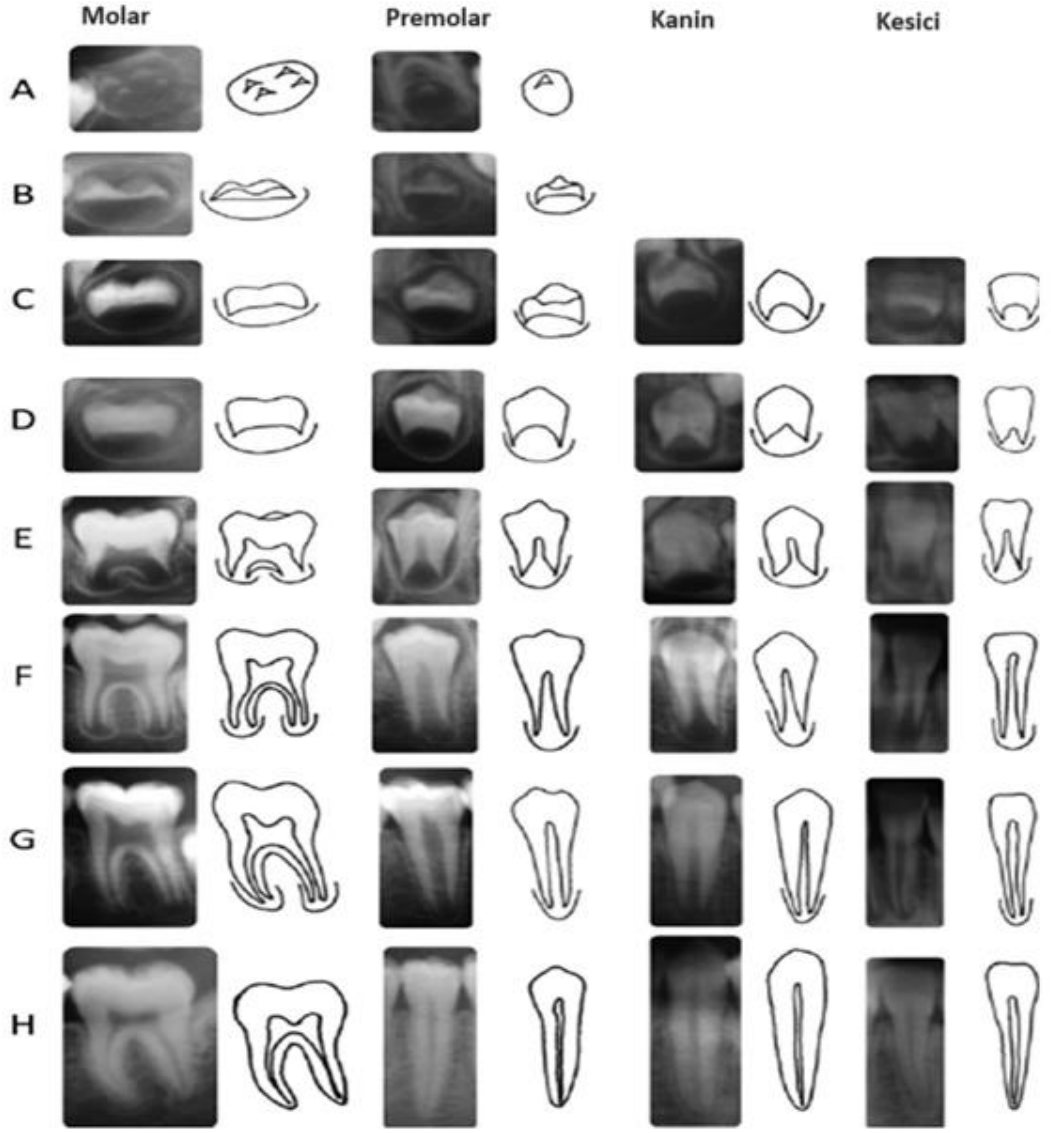
Yaş tahmininin geçerliliği kullanılan yöntem ve yöntemin doğru uygulamasına bağlı olmakla birlikte; bireyler arasında ve farklı coğrafi nüfus gruplarında diş gelişiminde farklılıklar bulunur. Aynı yaşta olan bireylerin tümü aynı düzeyde diş gelişimine ulaşamayabilir. Bölgesel farklılıkların sonuçlarda gösterdiği gibi, uygulanan yöntem yerel nüfusa uygun şekilde adapte edilmelidir [51].

Diş sürmesi; ankiloz, erken veya geç süt dişi kaybı, daimi dişlerin gömülü kalması veya yer darlığı gibi lokal faktörlerden etkilenebilmektedir. Bu nedenle Demirjian ve ark. yaş tayininde diş sürme yöntemlerinin sağlıklı veriler vermeyeceğini düşünerek, dış etkenlerden daha az etkilenen diş oluşumuna dayalı bir yöntem geliştirmişlerdir [52]. Yaş tayini ile ilgili çalışmalarda sık kullanılan ve literatürde kabul gören en geçerli yöntemlerden birisi olan Demirjian yöntemi, Türk toplumunda da kullanılmıştır [25].

Demirjian, Goldstein ve Tanner metodu (1973)

Demirjian metodu; 1973 yılında Demirjian ve ark.[52] tarafından geliştirilen yöntem, metrik ölçümler yerine radyograflar üzerinde morfolojik değerlendirmeyi kapsamaktadır. Bu yöntemde çocukların dental gelişimi panoramik radyograflar üzerinden değerlendirilmiştir. Sol mandibuladaki yedi daimi dişin mineralizasyon

aşamaları sekiz safhada(A-H) radyolojik olarak tanımlanmıştır ve her bir dişteki gelişim basamakları üzerinden oluşturulan sayısal değerler dental maturasyon tayini için kullanılmıştır. Diş sert dokuları, mineralizasyonun başlangıcından kök formasyonu tamamlanana kadar A'dan H'ye sekiz evreye ayrılmıştır (Şekil 2.3). Bu evrelerin ilk dördü olan A-D skorları kron mineralizasyonunu gösterirken, son dördü olan E-H skorları kök mineralizasyon derecelerini belirtmektedir. Bu yöntem; pratik, kolay uygulanabilir ve uzun yıllardır farklı ülkelerde yapılan araştırmalarla test edilen bir metottur. Özellikle 6 yaşına kadar olan çocuklarda, maksilladaki kemik yapısı nedeniyle radyograflardan elde edilen görüntü kalitesi sınırlıyken, mandibuladaki dişler panoramik radyograflarda daha net görüntü vermektedir [12, 52]. Bu metotta başlangıçta mandibular 14 diş kullanılmış olup, daha sonra sağ ve sol arasında belirgin simetri görüldüğü için sadece sol taraftaki 7 dişin kullanılmasına karar verilmiştir [26, 52]. 1976 yılında Demirjian ve Goldstein tarafından yöntem yaş grubu ve örnek sayısı genişletilerek incelenmiştir. İncelenecek diş grubu önce mandibular birinci molar, ikinci molar, birinci premolar ve ikinci premolarlar olacak şekilde belirlenmiş; sonrasında ise birinci molar dişin erken yaşta kaybının fazla olması sebebiyle çıkarılıp yerine santral kesici diş eklenerek dört dişten yaş tayini yapılmasını mümkün kılacak şekilde modifiye edilmiştir [53].



Şekil 2. 3 Demirjian sınıflaması A-H grupları görseli [52].

Tablo 2. 3 Demirjian sınıflaması A-H grupları açıklaması [52].

A	Hem tek köklü hem de çok köklü dişlerde tüberkül tepeleri kalsifiye olmuş; ancak henüz kaynaşmamış
B	Kalsifiye tüberkül tepeleri birleşmiş, okluzal yüzeyin sınırları belirgin
C	Okluzal yüzeydeki mine formasyonu tamamlanmış, dentin depozisyonu başlamış ve pulpa odasının ana hatları kıvrık
D	Kron oluşumu mine sement sınırında tamamlanmış, tek köklü dişlerin pulpa odası kıvrık, servikal bölgeye doğru konkavlaşmaya başlamış. Çok köklü dişlerin pulpa odası yamuk formunda, pulpa boynuzları farklılaşmaya başlamış. Kök formasyonu görülmeye başlar
E	Pulpa odasının duvarları düzgün, pulpa boynuzları daha belirgin. Kök uzunluğu kron uzunluğundan daha az, çok köklü dişlerde kök bifurkasyonları belirgin
F	Apeksler huni şeklinde sonlanır, kök uzunluğu kron uzunluğuna eşit ya da daha fazla
G	Kök kanal duvarları birbirine paralel, apeks kısmen açık
H	Apeks tamamen kapanmış, periodontal membran kök çevresinde ve apekte eşit kalınlıkta

Yaş tayini ile ilgili çalışmalarda sık kullanılan ve literatürde kabul gören en geçerli yöntemlerden birisi olan Demirjian yöntemi; farklı toplumlarda test edilmiş ve bu toplumlar arasında farklı sonuçlar saptanmıştır. Bunun üzerine Tunç ve ark.[54] panoramik grafi kullanarak yaptıkları çalışmalarında; Demirjian metoduyla kronolojik yaş tayininin Türk toplumundaki geçerliliğini değerlendirmiş ve sonucunda; 4-12 yaş arasındaki bireylerde, diş gelişim dönemleri ile kronolojik yaş arasında yüksek derecede korelasyon olduğu bildirilmiştir [26, 54].

2.4 Daimi Birinci Büyük Azı Diş

Daimi birinci molar dişlerin, kron oluşumu 3 yaş civarı tamamlanır ve ortalama 6-7 yaşlarında, süt dişi kaybı yaşanmaksızın, süt ikinci molar dişlerin distalinden ağız ortamına sürerler [55]. Daimi birinci molar dişler, daimi dentisyonda ağız ortamına ilk süren dişlerdir. Böylece erken çocukluk çağı dönemi sonlanır ve ağızda karışık dişlenme dönemi başlar [56]. Mandibulada daimi birinci büyük azı dişlerinin sürmesi, maksillaya göre yaklaşık 1-3 ay kadar daha önce gerçekleşir. Kök gelişimi de dişin okluzona gelmesinden yaklaşık 3 yıl sonra yani 9-10 yaş civarında tamamlanır [57]. Bu dişlerin sürmesi esnasında, genellikle olumsuz bir etki yaşanmadığı için

ebeveynlerin çoğu bu dişlerin sürdüğünün farkında değildir. Ancak, özellikle bu yaş grubunun, ağız hijyen eğitiminde ebeveynlerin özen ve dikkatine ihtiyacı vardır [55, 58]. Douglass [59] tarafından yapılan bir araştırmada, çocukların oral hijyen alışkanlıklarını yaklaşık 11-12 yaşlarından önce kazandıkları bildirilmiştir [59]. Ayrıca daimi birinci büyük azı dişlerindeki çürüme riskinin en yüksek olduğu dönemin dişlerin oklüzyona ulaşmadan önceki ilk 1-1,5 yıl olduğu ve daha sonraki yıllarda çürük riskinin giderek azaldığı bildirilmiştir [58, 60]. Daimi dişler içinde en fazla çürük görülen dişin, mandibular birinci büyük azı dişleridir [61, 62]. Bu dişlerin çürük riskinin yüksek olmasının en önemli nedenlerinin; morfolojik yapıları yani derin pit ve fissürlere sahip olmaları ile çocukların arka bölgeleri yeterince temizleyememesi olabileceği düşünülmektedir [56, 63].

Bunlara ilaveten; sistemik hastalıklar ve çevresel faktörlere bağlı olarak ya da gelişimsel defektler gibi etiyolojik faktörlerin olumsuz etkileri erken dönemde daimi birinci büyük azı dişlerinin çürüğe daha duyarlı hale gelmesine ve oluşan çürüğün ilerlemesiyle sergiledikleri zayıf prognoza bağlı olarak küçük yaşlarda kaybedilmesine neden olur. [64-66].

Daimi birinci büyük azı dişleri, çocukların büyüme-gelişimi ve sindirim sistemi üzerindeki önemli etkilerinin yanı sıra; çiğneme hareketlerinde ve vertikal yüz yüksekliğinin korunmasında da kritik bir rol oynamaktadır. Ayrıca bu dişler, çene yüz travmalarında, ortodontik tedavilerde, oklüzyonun fonksiyon ve dengesinin sağlanmasında büyük öneme sahiptir [55, 58]. Daimi birinci büyük azı dişlerinin nötral oklüzyonda kilitlenmesi, ileride sürecek olan daimi dişlerin sağlıklı bir şekilde normal oklüzyonda sürmelerine rehberlik eder [58]. Ayrıca bu dişler oklüzyonun anahtarı olarak görülmektedir [56]. Angle, "Tüm dişler temelde önemlidir, ancak bazı dişlerin önemi diğerlerinden daha fazladır. Özellikle oklüzyon anahtarını oluşturan daimi birinci büyük azı dişler en önemli olanlarıdır" sözüyle daimi birinci büyük azıların önemine vurgu yapmıştır [67]. Angle'a göre bu dişler, ağızdaki en büyük ve ankrajı en yüksek dişlerdir. Çiğnemeye, alt-üst çeneler arası dikey mesafeye, oklüzal yüksekliğe ve estetik oranlara etki ederler [68]. Gupta[69] ve Angle[67]; maloklüzyon sınıflamalarını mandibular daimi birinci büyük azıların maksiller daimi birinci büyük azıyla olan ilişkisine dayandığını belirtmiştir. Ayrıca bu dişlerin dentisyondaki fonksiyon ve stabilizasyon için stratejik öneme sahip olduğunu da vurgulamışlardır.

Bu nedenle daimi birinci büyük azıların eksikliğinde; normal büyüme ve gelişimde, fonasyonda ve oklüzyonda olumsuz etkilerin oluşabileceğini ve ortodontik problemlere yol açabileceğini ifade etmişlerdir [69].

2.4.1 Daimi birinci büyük azı dişlerin çekim endikasyonları

Daimi birinci büyük azı dişinin çekimine karar verilirken, çeşitli faktörler göz önünde bulundurulmalı ve gerektiğinde multidisipliner bir yaklaşım sağlanmalıdır. Klinik uygulamalar ve hasta kooperasyonunun belirlenmesinde medikal, sosyal ve dişsel hikâyelerle birlikte değerlendirme yapılmalıdır [70].

Anand ve ark.[71] tarafından Hindistan' da yapılan bir çalışmada; dört ayrı kliniğe başvuran hastaların bir aylık periyot boyunca daimi diş çekim nedenleri sınıflandırılmıştır. Elde edilen sonuçlara göre; en sık çekim yapılan dişler sırasıyla daimi birinci büyük azı dişi, birinci küçük azı dişi ve daimi ikinci büyük azı dişleridir. Büyük azı ve ikinci küçük azı dişler en sık diş çürüğü nedeniyle çekilirken, kesici ve kanin dişlerin çekimleri genellikle periodontal sorunlar nedeniyle yapılmaktadır. Bununla birlikte birinci küçük azı dişler ortodontik tedavi amacıyla en sık çekilen dişlerdir. Kesici ve kanin dişler protetik nedenlerden dolayı da çekilmektedir [1, 71].

Sandler ve ark.[72]' na göre birinci büyük azı dişlerin çekim endikasyonları şöyle sıralanabilir:[72, 73]

- Restore edilemeyecek kadar geniş çürüğe sahip veya hipoplazik birinci molar dişler,
- Premolar dişler sağlıklı iken geniş restorasyona sahip birinci molar dişler,
- Apikal patoloji görülen veya uygun yapılmamış kanal tedavisi olan birinci molar dişler,
- Arkın distal yarısında çapraşıklık görülmesi ve uygun pozisyonda yirmi yaş dişlerinin bulunması,
- Artmış maksillar/mandibular düzlem açıları,
- Anterior açık kapanışa sahip vakalar.

Albadri ve ark.[64] tarafından birinci büyük azı dişi çekilmiş 300 çocuk üzerinde yapılan çalışmada, çekilen dişlerin %70'inin çekim nedeninin kötü prognoz, %11'nin

ise daimi birinci büyük azı ve ön keser diş hipomineralizasyonu (MIH) olduğu tespit edilmiştir [64].

Şiddetli veya restorasyon yapılması imkansız büyük azı ve ön keser diş hipomineralizasyonu mevcut ise çekim düşünülür ve bu gibi durumlarda erken ortodontik değerlendirilme yapılması önemlidir. Bu noktada ortodontiye danışılarak şu faktörler değerlendirilmelidir:[74]

- Azıların prognozu ve restore edilebilirliği,
- Dental yaş,
- Bukkal bölge çapraşıklıkları,
- Üçüncü daimi azı dişlerin varlığı,
- Okluzal ilişkiler ve diğer sürmüş ve sürmekte olan dişlerin durumu.

Diş çekimi planlandığında, göz önünde bulundurulması gereken iki durum vardır: Birincisi, dişin çekiminin mümkün oldukça hızlı bir şekilde yapılması veya geçici olarak restore edilmesidir. İkincisi ise daimi birinci büyük azı dişlerinden bir tanesinin prognozu kötüyse diğer daimi birinci büyük azı dişin de çekilmesidir [1].

Daimi birinci büyük azı dişi çekimine karar verilirken; çekim kararı, hastaların eksik diş varlığı ve ağız içindeki mevcut dişlerinin durumu değerlendirilerek verilmelidir. Daimi birinci molarların çekiminden önce ikinci molar diş germinin pozisyonu, ikinci premoların durumu ve üçüncü molar diş germinin varlığı incelenmelidir [75]. Gelişen üçüncü büyük azı dişinin oluşturduğu kuvvet, birinci büyük azı dişi çekiminden kaynaklanan boşluğun kapanmasına yardım edebilir. Üçüncü büyük azı dişi yokluğunda ise, birinci büyük azı dişinin çekimi nedeni ile oluşan yer ideal olarak kapanmayabilir [70, 76].

2.4.2 Daimi birinci büyük azı dişlerin çekim zamanı

Daimi birinci büyük azıların çekimi düşünüldüğünde zamanlama iyi yapılmadığı takdirde çekim prosedürünün ardından sıklıkla ortodontik tedavi ihtiyacı oluşur [77-79]. Bazı durumlarda daimi birinci büyük azıların çekimi, ortodontik tedaviyi daha karmaşık hale getirebileceği için ortodontistler tarafından tercih edilmemektedir. Yaş faktörü dışında; çapraşıklık bulunmaması, uygunsuz iskeletsel yapı veya konjenital diş eksikliği gibi ortodontik sınırlamalar olabilir. Bu durumlarda, defektli dişlerin restorasyonu önerilmektedir [79]. Ancak, bazı vakalarda tüm tedavi seçenekleri

denenmesine rağmen defektli dişlerin tedavisi çekim ile sonuçlanmaktadır [74]. Aşırı defektli daimi birinci büyük azılar için en iyi tedavi seçeneğinin belirlenmesinde ortodontist ve pedodontistlerin birlikte karar vermesinin daha uygun olacağı bildirilmiştir [79].

Radyografik olarak ikinci büyük azı dişinin bifurkasyon bölgesi henüz mineralizasyon aşamasındayken yapılan ve üçüncü büyük azı dişlerinin germi mevcut olan hastalarda elde edilen oklüzyonun daha düzgün olduğu bildirilmektedir [80, 81]. Dolayısıyla kontrollü çekim kararı verilmeden önce bu kriterlerin sağlandığından emin olmak için birinci büyük azı dişlerinin durumunu ve dentisyondaki tüm dişlerin gelişimini gösteren, iyi kalitede radyografiler ile desteklenmiş detaylı bir klinik muayene yapılması gereklidir [82-84].

İdeal olarak ikinci büyük azı dişinin çekim boşluğuna paralel hareket edebilmesi için hastanın yaşının 8 ila 10 arasında olması gerekli görülmektedir [80, 81, 85]. Bu uygun yaş dönemi, radyografik olarak ikinci büyük azı dişinin kuron formasyonunun tamamlanıp kök oluşumunun üçte birlik kısmının bitmek üzere olduğu döneme denk gelmektedir [52, 86]. Bu dönem, Royal College of Surgeons of England Guideline’da “radyografide daimi ikinci büyük azı dişinin bifurkasyon kalsifikasyonun başlangıcı” olarak tanımlanmıştır [87]. Bu yaşlarda daimi birinci büyük azının çekimi gerçekleştirilirse komşu dişler birbirleri ile düzgün olarak kontak kurabilir [76]. Diş çekimi daha erken yıllarda yapılırsa, henüz sürmemiş olan komşu küçük azı dişi distale doğru kayabilir, eğimlenebilir veya rotasyon görülebilir [79]. Diş çekim zamanı gecikirse, çekim alanı tam olarak kapanamaz ve dişler arasında zayıf kontaklar oluşur [88]. Daimi büyük azı dişlerinin erken çekimi düşünüldüğünde, çekilecek dişin hangi çenede yer aldığı da önemlidir.

Daimi birinci büyük azı dişlerinin çekimlerinin erken veya geç yapılması durumunda maksilla ve mandibulada farklı sonuçlar ortaya çıkar [2].

Maksillada daimi birinci büyük azı diş çekimlerinin erken yapılması durumunda, boşluk çoğunlukla spontan olarak kapanmaktadır. Nadiren ikinci büyük azı ve ikinci küçük azı dişlerinin kontakt noktaları arasında 5-10 mm’lik boşluk kaldığı görülmektedir [80]. Çekimlerin geç yapılması sonucunda ise, ikinci büyük azı dişinin meziale doğru kayabileceği hatta devrilebileceği veya palatinal kök etrafında mesiopalatinal rotasyon yapabileceği bildirilmiştir [76].


Mandibulada daimi birinci büyük azı diş çekimlerinin erken yapılması sonucu olarak; ikinci küçük azı dişi sürme yolunda daha az dirençle karşılaşır ve çekim kavitesi içinde distal sürüklenme, devrilme ve rotasyon yaparak sürebilir. Çekimlerin geç yapılması sonucunda ise; lingual kemik daha ince olduğundan, ikinci büyük azı dişinin mesiolingual olarak devrilmesiyle çapraz kapanış ve çalışmayan taraf çatışmaları görülebileceği bildirilmiştir. Ayrıca ikinci küçük azı dişinde distale doğru devrilme gelişebileceği; bu dişler arasında kurulan zayıf kontakt ilişkilerine bağlı olarak da periodontal hastalıklar gelişebileceği ve alveolar kemik yıkımına ortam hazırlayabileceği ileri sürülmüştür [76].

Alt ikinci büyük azı dişinin kendiliğinden meziale hareketinin zorluğundan dolayı, çekim zamanı, alt çenede üst çeneye göre daha önemlidir. Üst çenede daimi ikinci azı dişi, pozisyonu ve sürme açısından dolayı daha düzgün bir şekilde mezialize olabilir [58].

Eichenberger ve ark.[89] tarafından yapılan bir meta analizde; daimi birinci büyük azı çekiminden sonra diş boşluğundaki spontan kapanmanın maksillada (% 72) mandibulaya (% 48) göre daha başarılı olduğu bildirilmiştir [89]. Erüpsiyon yolunun farklı oluşunun bu sonucun ortaya çıkmasında etkili olabileceği düşünülmektedir. Maksillada genellikle ikinci moların apeksi krona göre daha mezialde yer almaktadır [1]. Bu diş, mezial ve vertikal komponentleri ile eğrisel bir sürme yoluna sahiptir. Bu nedenle boşluğun spontan olarak kapanması sırasında mezializasyon özellikle rotasyonel hareketle olmaktadır [90, 91]. Mandibular daimi ikinci büyük azı dişlerin başlangıç pozisyonu ise daha istenmeyen bir durumdadır. Apeksi distale, kuronu da meziale konumlanacak şekilde eğimlidir ve daha vertikal bir sürme yolu vardır [75, 91]. Dolayısıyla diş boşluğuna spontan erüpsiyon için daha horizontal hareket etmesi gerekmektedir. Spontan kapanmanın mandibulada daha az görülmesinin nedenlerinden birinin de bu olduğu düşünülmektedir [75]. Mandibulada çekim bölgesine komşu dişlerin tipping hareketi görülebilmekte ve böylece prematür kontaklar ortaya çıkabilmektedir [92]. Bu prematür kontaklar fonksiyonel mandibuler kayma, temporomandibuler eklem sorunu ve mandibuler asimetri gibi problemlerin ortaya çıkmasına neden olabilir [93].

Hotz [94]; diş çekimi sonrası gerçekleşen fizyolojik hareketler için şu hususlara değinmiştir:

- Yürüme (drift, sürüklenme) hareketi çekim bölgesinden uzaklaştıkça azalır.
- Yürüme hareketinin tipi ve miktarı; tüberkül-fissür ilişkisinden, tüberkül biçimi ve dişlerin fonksiyonel kuvvetlere maruz kalma şeklinden etkilenir.
- Devrilme hareketi alt çenede daha belirgin bir şekilde görülür. Bunun sebebi üst çenedeki dişlerin eksen eğimleri diş apekslerinin üzerinde bir noktada birleşirken; alt çenede tam tersine birbirinden uzaklaşmasıdır.
- Bu duruma göre; üst çenede bir diş çekimi sonrasında komşuluğundaki dişler, çekim boşluğuna doğru yürürken eksenleri paralel bir hal alır. Ancak alt çenede, komşu dişlerin çekim boşluğuna hareketi eksen eğimleri paralellikten daha da uzaklaşacak ve klinik tablo kötüleşecektir. (Şekil 2.4)



Şekil 2. 4 Alt ve üst dişlerinin eksen eğimleri. Çekim sonrası radyografik değerlendirmelerde; alt çenede devrilme hareketi olurken, üst çenede devrilme hareketinin görülmesi daha güçtür [95].

- Paralel diş hareketi, henüz sürmemiş dişlerde daha fazla görülür.
- Sürmüş dişlerin çekim boşluğuna hareketi, distallerinde yer alan ve henüz sürmemiş dişlerin desteğiyle arttırılmaktadır.
- Mezial yönde yürüme hareketi, distalden daha fazladır ve bu durum üst çenede daha belirgindir [94].

Tüm daimi birinci azıların çekimi söz konusuysa, alt birinci azı dişlerin çekiminin üst birinci azı dişlerden önce yapılması önerilmektedir. Bu durumda alt ikinci azıların mezializasyonu için daha fazla zaman sağlanmış olur ve alt-üst azıların ideal oklüzyona gelmesine yardımcı olunur [75].

Balans ve/veya kompensasyon çekimlerinin gerekli olup olmaması, dişlerin sürme yolları, komşu diş ile olan ilişkileri, lokalizasyonları ve çene kemiklerinin yapısı gibi

durumlardan etkilenmektedir. Birinci büyük azı diři çekiminde, karřıt çenedeki diřin çekimi her zaman gerekli deęildir. Üst çenede, birinci büyük azı diři çekiminde kapanıřta bulunduęu alt çenedeki birinci büyük azı diřin çekimine ihtiyaç duyulmazken alt çenede; birinci büyük azı diři çekimi yapılırsa karřıt çenedeki birinci büyük azı diřinin çekimi düşünölmelidir [79, 88]. Hastada řiddetli çaprařıklık varsa, simetrik diř de çekilebilir. Böylece ortodontik problemin çözümlü de gerçekteřir [88]. Overjet ve sınıf 3 kapanıřın bulunduęu olgularda; çekimi gerekli olan birinci büyük azı diřinin dıřındaki birinci büyük azı diřleri aęızda tutulmaya çalıřılmalıdır [70].

Daimi alt birinci azı diřlerin çekiminde çift taraflı molar kapanıř iliřkisi sınıf 1 ise, bukkal segment iliřkisini korumayı teřvik etmek için üst birinci azıların kompensatif çekimi de gerekir [61]. Bu řekilde, üst birinci büyük azının erüpsiyonu engellenmekte ve genellikle üst ikinci büyük azının iyi bir pozisyonda sürmesine olanak saęlanmaktadır. Bununla birlikte, eęer bir üst birinci büyük azı çekilmek durumunda ise antagonisti yerinde bırakılabilmektedir. Bunun nedeni, alt ikinci moların nadiren iyi bir spontan bořluk kapanması göstermesi ve alt büyük azı diřlerin karřıt bořluęa doęru üst diřlerden daha az erüpsiyon göstermesidir [73, 75].

Oklüzyonun düzgün bir řekilde saęlanabilmesi için daimi birinci büyük azı diřlerinin kompensasyon ve balans çekimlerine karar verirken doęru zamanlama ve detaylı inceleme önem tařımaktadır [2]. Angle sınıf 1 oklüzyon tipine sahip hastalar için kompensasyon ve balans çekimi gereklilięi řöyle özetlenebilir:

Tablo 2. 4 Zorunlu çekimi gereken dişler için kompenzasyon ve balans çekimleri [2].

Zorunlu Çekimi Gereken Diş		
	Maksiller birinci büyük azı	Mandibular birinci büyük azı
Kabul edilebilir overjet ve/veya hafif çapraşıklık	Balans ve kompenzasyon çekimi gerekli değildir.	Kompenzasyon çekimi gerekli, balans çekimi gerekli değildir.
Kabul edilebilir overjet ve/veya orta dereceli çapraşıklık	Kompenzasyon çekimi gerekli değil, orta hattı korumak ve arkın kontralateral tarafında rahatlama sağlamak amacıyla balans çekimi gereklidir.	Kompenzasyon ve balans çekimi gereklidir.
Kabul edilemez overjet ve/veya ileri derecede bukkal çapraşıklık ve/veya labial çapraşıklık	İkinci büyük azı dişlerinin sürmesine kadar beklenir. Ardından ortodontik tedavi uygulanır. Orta hattı korumak için balans çekimi yapılabilir.	İkinci büyük azı dişlerinin sürmesine kadar beklenir. Ardından ortodontik tedavi uygulanır. Maksiller büyük azı dişlerin overerüpsiyonunu engellemek için palatal ark ve J-hook headgear kullanılabilir.

Çekimi yapılan mandibular birinci azı dişine komşu tüm dişler çekim bölgesine doğru hareket eder. Çekim bölgesine yakın olan dişlerin daha belirgin açısız değişiklikler sergiledikleri bildirilmiştir. Thunold [81], ikinci küçük azı dişe oranla ikinci büyük azı dişinin daha fazla hareket ettiğini bildirmiştir [81].

Angle Sınıf II Divizyon 1 olgularda çekim kararı verilirken oklüzyon ve üçüncü büyük azı dişinin germ varlığına göre değerlendirilme yapılmaktadır. Zayıf prognozlu mandibular birinci büyük azı dişinin çekiminden sonra maksiller birinci büyük azı dişi, mandibular süt ikinci azı dişi ile kontakt halindedir. Bu kontakt maksiller birinci büyük azının overerüpte olmasını engellediğinden genellikle kompenzasyon çekimine gerek olmadığı ancak overerüpsiyon ihtimali olan hastalarda ise bu durumu engellemek amacıyla transpalatal ark uygulanabileceği bildirilmiştir [96]. Overjeti azaltmak ve bukkal segmentteki çapraşıklığı rahatlatmak amacıyla, maksiller arkta daimi birinci büyük azı dişinin çekim boşluğunun kullanıldığı olgular mevcuttur [97]. Bu durumda birinci büyük azı dişlerinin çekimleri ikinci büyük azı dişleri oklüzal seviyeye ulaştıktan sonra ertelenir. Ardından ikinci büyük azı dişlerinin meziale göçünü

önlemek için de palatal ark veya J-hook headgear kullanılır ve çekim boşluğu ortodontik tedaviyle hizalanır [76]. İleri derecede çapraşıklık olan Angle sınıf II divizyon I vakalarında; üçüncü büyük azı dişinin germi her iki arkta da mevcutsa zayıf prognozlu birinci büyük azı dişleri ile kompenzasyon ve balans çekimlerinin ideal zamanında yapılması gerektiği; ikinci büyük azı dişi sürdükten sonra ise gerekiyorsa, maloklüzyonun düzeltilmesi için küçük azı dişlerinin de çekiminin yapılabileceği belirtilmiştir. Maksiller üçüncü büyük azı dişlerinin germi mevcut değilse, zayıf prognozlu tüm birinci büyük azı dişlerinin çekimlerinin yapılması; ancak kompenzasyon çekimlerinin yapılmaması önerilmektedir [98].

Sınıf II Divizyon II vakalarında; düzgün bir overbite'ın teminini sağlamak oldukça zor olabilir. Birkaç retrospektif çalışmada daimi birinci büyük azı çekimleri ile keser dişlerde dikleşme ve overbite'da artış arasında ilişkisine dair kanıtlar sunulmuştur [81, 99, 100]. Maloklüzyonu daha da şiddetlendireceği için bu tip vakalarda alt dişlerin çekiminden mümkün olduğunca uzak durulmalıdır [76, 98, 101].

Angle Sınıf III vakalarında; daimi birinci büyük azı dişlerin çekildiği hastaların tedavi planı ve çekim kararının verilmesi oldukça zordur. Maksiller daimi birinci büyük azı dişlerin mümkün olduğunca balans ve kompanzasyon çekimlerinden uzak durulması gerekir [76, 98]. Eğer çekim yapılması zorunluysa bu işlem doğru endikasyonla ideal zamanlama ile yapılmalıdır [101]. Doğru endikasyon konulmuş olgularda daimi birinci büyük azıların kontrollü çekimi sonrasında; önce daimi ikinci büyük azı sonrasında üçüncü büyük azı dişlerinin mezial yönde paralel hareketi ile uygun bir okluzal ilişki elde edilebilir [76, 98].

2.4.3 Daimi birinci büyük azı dişlerinin çekim komplikasyonları

Daimi birinci büyük azı dişlerinin erken çekimi çenelerde oklüzyon bozukluklarına, posterior dişlerde çapraz kapanışa, dişeti çekilmelerine neden olabilir Dişetindeki bu çekilme sonucu sement açığa çıkmakta ve sementin yapısından dolayı da diş yüzeyinde hassasiyet ve erken çürükler oluşabilmektedir [70].

Normando ve ark.[102] tarafından yapılan bir çalışmada; tek taraflı birinci büyük azı dişi çekilen bireylerin çekim yapılmamış tarafa göre, çekim bölgelerindeki alveol kemiğinde yaklaşık 2 mm rezorpsiyon olduğu belirtilmiştir [102].

Daimi birinci büyük azı dişlerinin çekimleri bazen zorunlu olsa da, kontrolsüz yapıldığında dental arktaki diğer dişlerin boşluğa doğru devrilmelerine, yer değiştirmelerine bazen de uzamalarına neden olabilmektedir [86, 102, 103]. Ayrıca büyüme ve gelişim döneminde daimi birinci büyük azıların tek taraflı çekimlerinin; orta hat sapmalarına, tek taraflı çığneme alışkanlığına, oklüzyon bozukluklarına bağlı olarak özellikle yüzün alt üçlüsünde iskeletsel asimetrilere ve temporomandibuler eklem bozukluklarına neden olabildiği bildirilmiştir [90]. Sonuç olarak, çekim planlanırken, ileri dönemde telafi edilmesi zor ve hatta bazen imkansız olabilen ciddi oklüzyon düzensizliklerinin ortaya çıkabileceği göz önünde bulundurulmalıdır [86]. Bunlara bağlı olarak kontrolsüz çekim, tedavisi zor, uzun ve masraflı ortodontik tedavi gereksinimine neden olabilmektedir [61]. Bu nedenle zayıf prognoza sahip birinci büyük azı dişlerinin uygun zamanda çekilmesi; ark simetrisini sağlamak ve oklüzal ilişkilerin stabilitesini korumak için önemlidir. Herhangi bir patoloji olmasa bile birinci büyük azı dişlerin karşı taraf balans ve/veya karşıt arktaki kompenzasyon çekimlerinin kontrollü bir şekilde planlanması daha kabul edilebilir bir oklüzyonla sonuçlanmasını sağlayabilir [2, 98, 104]. Zira kontrollü ve uygun zamanda yapılan daimi birinci büyük azı dişlerinin çekim planlaması sonucunda, ikinci büyük azı ve takiben üçüncü büyük azı dişlerinin çekim boşluğuna doğru mezial yönde paralel hareket edeceği ve uygun bir oklüzal ilişkinin elde edilebileceği varsayılmaktadır [98].

2.5 Panoramik Radyografi

Panoramik radyografi (ortopantomografi), maksiller ve mandibular dental arkları ve arklara komşu anatomik yapıları bir arada ve tek bir görüntüde inceleyebilmek için kullanılan bir görüntüleme yöntemidir (Şekil 2.5). Panoramik radyografiler ile dentisyon, gömülü dişlerin konumu, dişlerin gelişim ve sürme durumları, temporomandibular eklem bölgesi, çene yüz travmaları, maksillofasiyel gelişim bozuklukları, çene kemiklerini içeren kist, tümör, enfeksiyon gibi patolojiler değerlendirilebilir [84].

İntraoral radyografilere oranla daha az anatomik detay vermesi, magnifikasyon ve geometrik distorsiyon gibi dezavantajlarının yanı sıra, düşük radyasyon dozu ve kısa sürede görüntü oluşumu gibi avantajları mevcuttur [31, 84]. Periapikal radyografide görülemeyecek kadar büyük olan belirli bir bölge olduğunda, panoramik radyografi tercih edilen yöntem olabilir [105, 106].



Şekil 2. 5 Panoramik radyografi, Planmeca Promax 2D (Planmeca, Helsinki, Finland).

2.5.1 Panoramik radyografi endikasyonları

- Çocuklarda ve karışık dişlenme dönemindeki bireylerde diş sürme ve gelişiminin izlenmesi
- Erişkinlerde üçüncü büyük azı dişlerinin lokalizasyonlarının belirlenmesi
- Çene ve yüz travmaları
- Çene kemiklerindeki kistik ve malign lezyonların tanısı
- Dişsiz hastalarda protez planlanması
- Maksillofasiyel iskeletin gelişimsel bozuklukları
- Cerrahi girişim öncesinde, operasyonun planlanmasında ve sonrasında postoperatif iyileşme takibi
- Temporomandibular eklem rahatsızlıklarının değerlendirilmesi
- Dental implant girişimi öncesinde ve sonrasında inceleme yapılması [84, 107]

2.5.2 Panoramik radyografi avantajları

- Uygulaması kolay ve non-invazivdir.
- Hem alt hem üst çeneyi kapsayan geniş bir görüntü alanı içerir.
- Ağız açma kısıtlılığı olan hastalarda kolaylıkla kullanılabilir.

- Serigrafiye göre düşük radyasyon dozu içerir.
- Hızlı, kullanışlı ve kolay uygulanabilir bir tekniktir [84, 107].

2.5.3 Panoramik radyografi dezavantajları

- Görüntüler intraoral radyografilerdeki kadar net değildir. Periodontal hastalık ya da apikal lezyon gibi durumlarda yeterli netliği sağlamayabilir.
- Fokal trough (odak aralığı) sınırlı olduğundan bu alanın dışında kalan oluşumlar net görülemez.
- Magnifikasyon ve distorsiyon nedeni ile görüntüde alveol kemiği yüksekliği ve kök boyu gibi ölçümler güvenilir şekilde yapılamaz.
- Panoramik radyografi cihazları periapikal radyografi cihazlarına göre daha pahalıdır [107].

2.6 Yapay Zekâ Nedir?

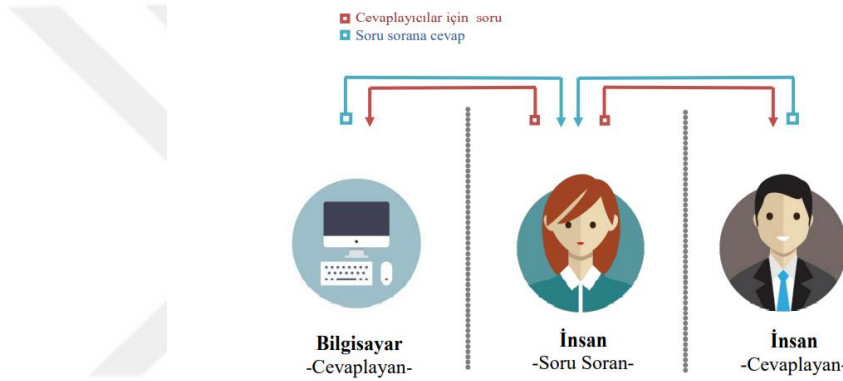
Yapay zekâ, insan zekâsına özgü olan, algılama, öğrenme, düşünme, çoğul kavramları bağlama, fikir yürütme, iletişim kurma, sorun çözme, çıkarım yapma ve karar verme gibi yüksek bilişsel fonksiyonları veya otonom davranışları sergilemesi beklenen yapay bir işletim sistemidir. Yapay zekâ kısaca; insan gibi düşünen, insan gibi davranan, mantıksal düşünen, mantıksal davranan bir sistemdir. Bu bağlamda yapay zekâyı geliştirirken insan beyninin biyolojik anatomisinden ilham alınmıştır [108].

Görüntü tanıma, dijital asistanlar ve otonom arabalar gibi gelişmeler, yapay zekânın bir sistemin dış verilerini doğru bir şekilde yorumlama, bu verilerden öğrenme ve bu öğrenimleri kullanma kabiliyetine dayanmaktadır. Bu gelişmeler insan beynindeki sinir ağlarını taklit eden yapay sinir ağlarının modellenmesi sayesinde mümkün olmuştur [109].

Yapay zekâ algoritmaları; deneyimleri anlama ve öğrenme, sonuçları değerlendirme ve farklı durumlar arasındaki benzerlikleri bulma yeteneğine dayanır. Bilgi, ağ tarafından bir öğrenme süreci yoluyla çevresinden edinilir [110].

2.6.1 Yapay zekânın tarihsel gelişimi

Yapay zekânın temelini oluşturan ilk çalışma, 1950 yılında Alan Turing tarafından yazılan, The Mind dergisinde yayınlanan, “Hesaplama makineleri ve zekâ” başlıklı makaledir. Bu makalede Alan Turing “Makineler düşünebilir mi?” sorusunu yöneltmiş ve bu soruyu iyi anlayabilmek için bir Turing testi adı verilen bir test önerisi sunmuştur (Şekil 2.6). Bu test, bir diyalog içerisinde karşıdaki kişinin yapay zekâ mı yoksa gerçek insan mı olup olmadığını ölçmeye çalışan bir test türüdür [111]. Gerçekleştirilen testin varmak istediği sonuç, yapay zekâ algoritmaları ile oluşturulan sistemin insan zekâ seviyesine ulaşma durumunu tespit ederek makinenin öğrenme ve düşünebilme yeteneğine sahip olup olmadığını belirlemektir [112].



Şekil 2. 6 Turing testi [111].

Yapılan bir diğer önemli çalışma; John McCharty tarafından ilk kez yapay zekâ teriminin kullanıldığı 1956 yılındaki Dartmouth çalıştıdır. Bu dönemde, mantıksal düşünce, problem çözme ve dil işleme gibi konularda temel algoritmalar geliştirilmeye başlanmıştır. 1960’larda artık daha uzman insan benzeri kararlar alabilen programların temeli atılmıştır. 1964 yılında, Massachusetts Institute of Technology (MIT)’nin yapay zekâ laboratuvarlarında Joseph Weizenbaum tarafından geliştirilen ELİZA isimli program yapay zekâda doğal dil işleme programlarının ilk örneği olmuştur. 1980’lerde yapay zekâ çalışmaları azalmış ve 1990’lara kadar ciddi bir ilerleme kaydedilememiştir. 1990’larda makine öğrenmesi alanı ile beraber yapay zekâ çalışmalarında tekrar bir sıçrama olmuş ve ciddi adımlar atılmaya başlanmıştır. 1997 yılında dünya satranç şampiyonu Gary Kasparov ile International Business Machines (IBM) tarafından geliştirilen satranç oynama programı Deep Blue, büyük bir duyuru ile bütün dünyanın izlediği bir maçta karşı kaşıya gelmiş ve Deep Blue Kasparov’u

yenmiştir. 2010'ların başından itibaren derin öğrenme olarak adlandırılan bir tür yapay sinir ağı kullanılarak yapay zekâ algoritmalarında tekrar bir sıçrama yaşanmış ve insan beyninden ilham alınan algoritmalar kurulmuştur 2011 yılında Apple dijital asistan Siri'yi tanıtmıştır. Siri'nin görevi gerçek bir asistan gibi kullanıcısının soru ve faaliyetlerine hızlı cevap vermek ve yardımcı olmaktır. Ayrıca IBM'in tasarladığı Watson adlı yapay zekâ bir bilgi yarışmasında tüm soruları bilmiştir. 2015 yılında Google'ın Alpha Go adlı yapay zekâsı, satranca göre çok daha karmaşık olan Go oyununda dünya şampiyonlarını yenmiştir. Yapay sinir ağları ve derin öğrenme, günümüzde yapay zekâ etiketi altında bildiğimiz çoğu uygulamanın temelini oluşturmuştur. Google 2018 yılında, dönüştürücü ağ tabanlı doğal dil işleme modeli olan BERT' i yayınlamıştır. 2021 yılında ise Open AI tarafından yazıyla tarif edilen resimleri üretebilme yeteneği olan DALL-E adlı çalışma tanıtılmıştır. Bugün, yapay zekâ alanındaki çalışmalar hızla devam ediyor ve robotik, otomasyon, sağlık, finans ve daha pek çok sektörde büyük etkiler yaratıyor. Bu alanların ihtiyacına göre makine öğrenmesi algoritmaları hala yeterince verimli sonuçlar alırken, onun yetersiz kaldığı durumlarda insanın sinir sistemi anatomisini taklit eden derin öğrenme teknikleri sürücüsüz araç teknolojileri, hastalık teşhisi, moleküler modelleme vb. pek çok konuda yardımcı olmaya devam ediyor.

2.6.2 Yapay zekânın amaçları


Yapay zekânın amaçları aşağıdaki gibi özetlenebilir [113]:

- İnsan beyninin fonksiyonlarını bilgisayar modelleri yardımıyla anlamaya çalışmak.
- İnsanların sahip olduğu zihinsel yetenekleri, bilgi edinme, öğrenme ve buluşlarda uyguladıkları strateji, metot ve teknikleri araştırmak.
- Bu öğrenme metotlarını işlevselleştirmek ve bilgisayarlarda bilgi sistemleri şeklinde uygulamak.
- İnsanların bilgisayar kullanımını kolaylık sağlayacak insan/bilgisayar ara birimleri geliştirmek.
- Belli bir uzmanlık alanı içindeki bilgileri bir “bilgi sistemi” şeklinde toplamak.
- Geleceğin bilgi toplumunun kurulmasında önemli rol alacak “genel bilgi sistemleri” geliştirmek.

- Bilimsel araştırma ve buluşlarda yararlanmak üzere “araştırma yardımcıları” geliştirmek.

Yapay zekâ uygulamaları üç alt kategoride incelenebilir [114].

- Kural Tabanlı Yapay Zekâ (Uzman Sistemler, Karar Destek Sistemleri, Algoritmalar vb.)
- Karar Veren Yapay Zekâ (Genetik Algoritma Kodu, Metin Madenciliği vb.)
- Öğrenen Yapay Zekâ (Makine Öğrenmesi, Derin Öğrenme, Yapay Sinir Ağları vb.)



Şekil 2. 7 Yapay zekâdan derin öğrenmeye temel kavramlar [115].

2.7 Makine Öğrenmesi

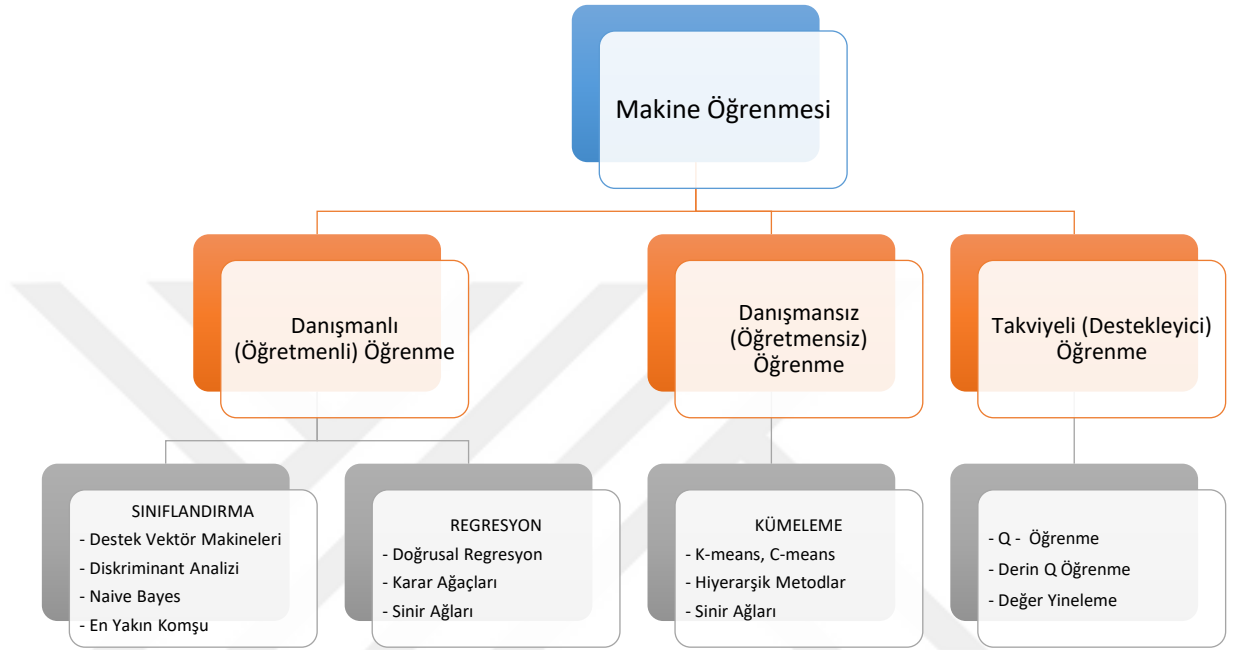
Makine öğrenimi, bilgisayar sistemlerinin verilerden öğrenme, desenleri tanıma ve kararlar alabilme yeteneğini geliştiren bir yapay zekâ alanı olarak tanımlanır. Makine öğrenimi, bir bilgisayarın kapsamlı veri tabanlarından bilgi çıkarıp sonuçları sınıflandırması veya tahmin etmesi mümkündür. Verilere daha fazla maruz kaldıkça makine öğrenimi algoritmaları geliştirilir; böylece bilgisayarlar sadece kurallara bağlı kalmazlar, deneyimle gelişirler, büyük miktarda veriyi değerlendirerek belirli cevaplar vermeyi öğrenirler [5].

Makine öğrenmesi, yapay zekânın bilgisayar bilimlerine uygulanabilmesi için geliştirilen bir alandır. Eğitim seti olarak adlandırılan veri kümesinden alınan girişleri kullanarak öğrenebilen ve sonrasında tahminde bulunabilen algoritmaları oluşturmayı amaçlamaktadır. Makine öğrenmesi bu öğrenme işinin bilgisayarlar üzerinden gerçekleştirilmesini sağlamaktadır [112].

Takviyeli öğrenme, kural tabanlı öğrenim, öğrenim sınıflandırma sistemleri, genetik algoritmalar, yapay sinir ağları, karar ağaçları, derin öğrenme gibi birçok

makine öğrenme algoritması vardır. Makine öğrenmesi, çeşitli algoritmalar kullanılarak veri setlerinde anlamlı desenlerin bulunmasını ve bu desenlerin yeni verilere uygulanarak sonuç elde edilmesini sağlar. Bu algoritmalar yapay zekânın temel yapı taşlarından biri olarak kabul edilir [112, 116].

Makine öğrenmesi yöntemleri üç grupta toplanabilmektedir:



Şekil 2. 8 Makine öğrenmesi yöntemleri [117].

2. 7. 1 Danışmanlı (öğretmenli) öğrenme

Danışmanlı (öğretmenli) öğrenme yönteminde öğretene ihtiyaç duyulmaktadır. Probleme ait giriş değerleri için çıktı değerlerinin de sisteme verilmesi gerekmektedir. Bu tip öğrenmede sisteme verilen girdiler, çıktı karşılıkları için modelde bulunan ağırlıkların en uygun değeri güncellenerek bulunur. Güncel ağırlıklar, ağırlık bulduğu çıktı değeri ile beklenen çıktı arasındaki farka göre hesaplanır. Başka bir deyişle, danışmanlı öğrenme, bir dizi eğitim örneğinden oluşan elle etiketlenmiş eğitim verilerinden yapılan çıkarımla, beklenen bir çıktıyı elde etmek için hesaplamaları gerçekleştirmeyi ve ardından hatayı belirlemeyi ifade eder. Bu sistemler elle etiketlenmiş görüntüleri analiz ederek normal ve anormal özellikleri tespit etmeyi öğrenir. Danışmanlı (öğretmenli) öğrenmeye örnek olarak Çok Katmanlı Yapay Sinir Ağları verilebilir [112, 117, 118].

2.7.2 Danışmansız (öğretmensiz) öğrenme

Danışmansız (öğretmensiz) öğrenme yönteminde sistemin öğrenmesi için sisteme etiketlenmiş çıkış verileri yerine sadece problem ile ilgili giriş verileri verilmektedir. Eğitim sırasında sisteme giriş verilerine karşılık gelen çıkış verilmediği için sistem parametreler arasındaki ilişkiyi kendi kendine öğrenmeye çalışır. Danışmansız öğrenme yöntemi, girdi modeline dayalı olarak kendi başına makine öğrenmesidir. Giriş verileri etiketlenmez ama farklı kümelere ayrılır; bu nedenle, bu öğrenme yöntemiyle geliştirilen modeller kümeleme algoritmaları olarak da bilinir. Ayrıca yapay zekânın bir parçası olan bu yöntem, veri analitiği ve veri madenciliği alanlarında da önemli rol oynamaktadır [112, 117, 119].

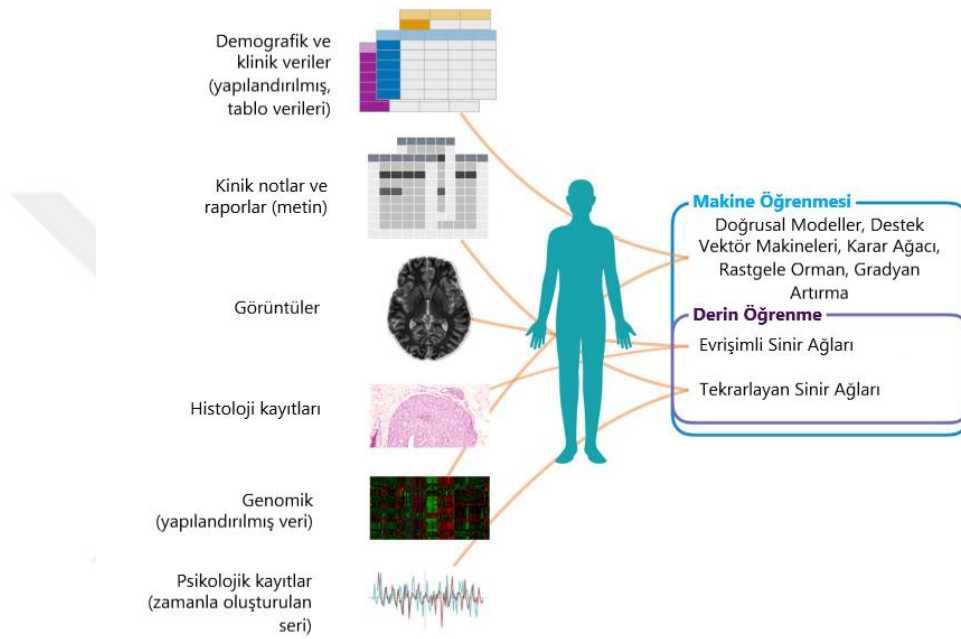
2.7.3 Takviyeli (destekleyici) öğrenme

Takviyeli öğrenme sistemlerinin danışmanlı ve danışmansız öğrenme sistemlerinin benzerliklerini içerir. Danışmansız öğrenme yönteminde olduğu gibi sisteme probleme ait sadece giriş bilgileri verilir ancak sistem için bir danışman bulunarak sonuçların doğru veya yanlış olduğu belirlenir. Dolayısıyla çıkış bilgileri verilmese de sistem sonucun doğru olması için danışman tarafından desteklenir ve rehberlik edilir. Bu yöntemde sistem, doğru çıktılar için ödül olarak belirli hedeflere ulaşmaya teşvik edilirken, yanlış çıktılar için ceza olarak hatalardan kaçınmaya çalışır. Böylelikle sistem, deneyimlerden öğrenir ve gelecekte belirli hedeflere ulaşmak için pekiştirilir. Takviyeli öğrenme, özellikle belirli bir amacı olan etkileşimli ve dinamik ortamlarda kullanılır. Mesela oyun oynama, robot kontrolü, finansal ticaret ve trafik yönetimi gibi alanlarda etkili bir şekilde kullanılır [112, 117, 118, 120].

Derin öğrenme, bu üç makine öğrenimi yöntemiyle de gerçekleştirilebilir. Ancak, eğitim sürecinde büyük miktarda etiketlenmiş veri gerektiren bir yöntem olduğu için danışmanlı makine öğrenimi derin öğrenme için en fazla kullanılan makine öğrenimi çeşididir [121].

Yapılandırılmış ve yapılandırılmamış veriler farklı makine öğrenmesi algoritmaları kullanılarak analiz edilir. Doğrusal modeller, eklemeli modeller, destek vektör makineleri, rastgele orman, karar ağaçları ve gradyan artırma yapılandırılmış verileri analiz etmek için kullanılan algoritmalarıdır. Yapılandırılmamış veriler iki ana

yol ile analiz edilebilir. Birinde; veriler yapılandırılabilir ve sonrasında yapılandırılmış veriler üzerinde başarılı olan bir algoritma kullanılabilir. Diğerinde ise yapılandırılmamış verileri doğrudan işleyebilen ve ara dönüşüm olmadan toplam bilgiden yararlanabilen bir algoritma sınıfı kullanılabilir. Yapay sinir ağları, yapılandırılmamış veri türlerinin analizinde oldukça başarılı olan geniş bir algoritma ailesini temsil eder. Şekil 2.9’da tıbbi veri çeşitleri ve bunlar üzerinde kullanılacak makine öğrenimi algoritmaları gösterilmektedir [122].




Şekil 2. 9 Sağlık alanında veri çeşidine göre kullanılan makine öğrenmesi yöntemleri [122].

2.8 Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin en önemli özelliklerinden biri olan öğrenme fonksiyonunu modelleyerek tahmin edebilme, yeni bilgi çıkarımı yapabilme gibi becerileri makinelere kazandırmayı amaçlar. İnsan beyninin biyolojik sinir hücreleri veya nöronları model olarak kullanılmıştır (Şekil2.10).

Sinapslar, biyolojik sinir hücrelerinin birbirleri ile iletişim kurma araçlarıdır. Sinir hücrelerinin dendritleri, sinyalin işlendiği ve aksona iletiildiği soma olarak bilinen sinir hücresinin çekirdeğine iletilen bir giriş sinyali alır. Akson, somadan gelen sinyali sinapsa taşır ve daha sonra sinyal bir sonraki nöronun dendritine aktarılır. Benzer şekilde yapay sinir hücreleri de dışarıdan gelen bilgileri bir toplama fonksiyonu ile

toplar ve aktivasyon fonksiyonundan geçirerek çıktığı üretilen ağın bağlantılarının üzerinden diğer hücelere yani proses elemanlarına iletirler [112, 116, 117].

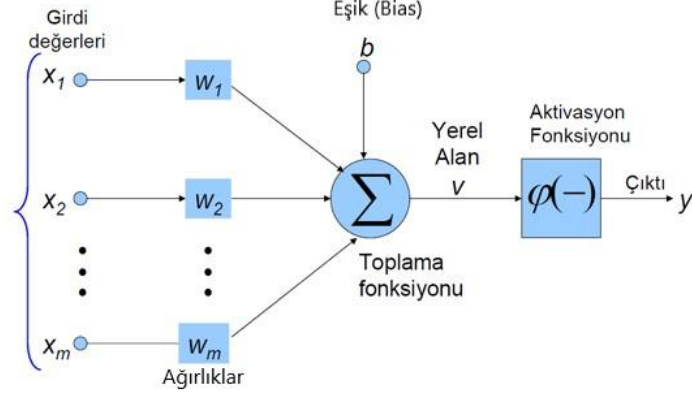


Şekil 2. 10 Biyolojik sinir hücresi ve yapay sinir ağı [123].

Tablo 2. 5 Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları [112].

Nöron	Proses elemanı
Dentrit	Toplama fonksiyonu
Hücre gövdesi	Aktivasyon fonksiyonu
Aksonlar	Nöron çıkışı
Sinapslar	Ağırlıklar

Yapay sinir ağlarını birbirlerine bağlayan bağlantıların değerlerine ağırlık değerleri denir. Bir yapay sinir hücresi beş temelden oluşmaktadır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılarıdır (Şekil 2. 11).



Şekil 2. 11 Yapay sinir hücresinin yapısı [112].

Şekilde girişler x_i ağırlıklar ise w_i ile gösterilmiştir. Girdi değerlerinin her biri kendilerine denk gelen ağırlık değerleriyle çarpıldıktan sonra elde edilen bilgiye eşik değeri eklenir. Daha sonra sonucun alınması için aktivasyon fonksiyonu uygulanır ve çıktı değeri (y) elde edilir. Aktivasyon fonksiyonu çıktı değerlerini belirlemek için kullanılan matematiksel bir işlemidir. Mimari içerisindeki ağırlıkların doğru bir şekilde güncellenmesi yapay sinir ağlarının öğrenme kabiliyetini belirler [112].

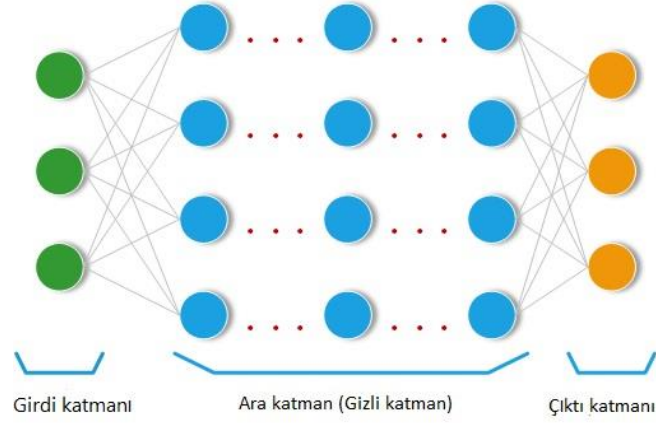
2.8.1 Yapay sinir ağlarının yapısı

Proses elemanları yani yapay sinir hücreleri, birbirlerine paralel olarak üç katman halinde bir araya gelerek bir ağ meydana getirirler. Bu üç katman şunlardır (Şekil 2.12): [112, 116, 117]

Girdi katmanı: Ağa verilerin girişini kabul eder. Bu katman, dış dünyadan alınan ham verileri, ağın anlayabileceği ve işleyebileceği bir formata dönüştürür ve diğer katmanlara ileterek işlemleri başlatır.

Ara Katman (Gizli Katman): Girdi katmanından gelen verileri işleyen ve çıktı katmanına ileten bir dizi yapay sinir hücresinden oluşur. Bu katman, girdi verilerindeki özellikleri ve desenleri algılayarak önemli özelliklerin çıkarılmasını sağlar. Ara katman; bir veya daha fazla katmandan oluşabilir ve yapay sinir ağlarının derinlik kazanmasına olanak tanır.

Çıktı Katmanı: Ara katmandan gelen işlenmiş verileri kullanarak çıktıları elde eder ve ağın sonucunu verir. Ayrıca genellikle problemin çözümüyle ilgili bilgi içerir [112].




Şekil 2. 12 Çok katmanlı yapay sinir ağı şeması [112].

Yapay sinir ağları birçok nöron ve gizli katmandan oluşuyorsa buna çok katmanlı sinir ağı, tek bir katmandan oluşuyorsa tek katmanlı sinir ağı denir.

Yapay sinir ağı modelleri, katman sayılarına göre tek katmanlı ve çok katmanlı, sinirler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre ileri beslemeli ve geri beslemeli ağlar olarak toplam dört grupta incelenebilir [112].

2.8.1.1 Tek katmanlı algılayıcılar

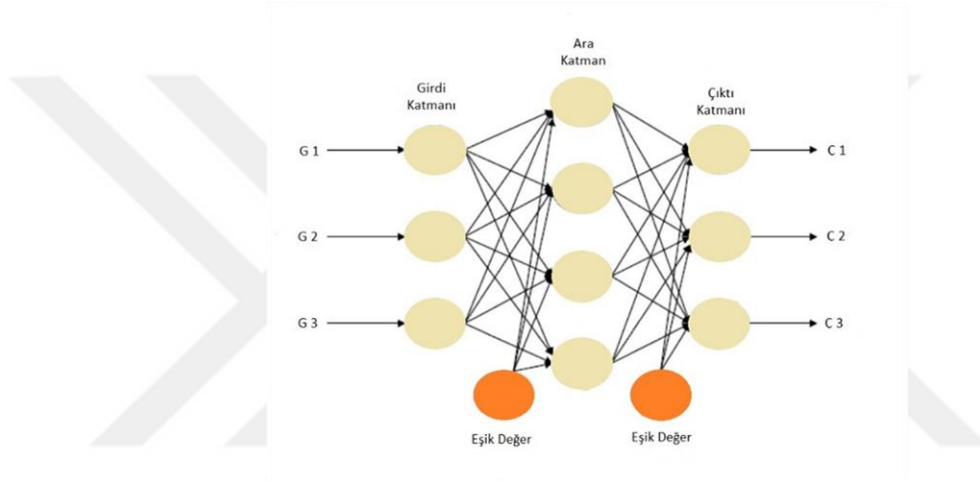
Tek katmanlı sinir ağları sadece girdi ve çıktı katmanından oluşmaktadırlar (Şekil 2.13). Bu ağlar; doğrusal ilişkileri ve basit problemleri çözme yeteneğine sahip olabilir, ancak karmaşık problemleri cevaplamada ve doğrusal olmayan ilişkileri öğrenmede yetersiz kalabilirler [112, 116].



Şekil 2. 13 İki girdi ve bir çıktıdan oluşan tek katmanlı bir yapay sinir ağı [116].

2.8.1.2 Çok katmanlı algılayıcılar

Tek katmanlı sinir ağları karmaşık problemleri çözmek ve doğrusal olmayan ilişkileri öğrenmek için yetersiz kaldığından hem mimari hem de eğitim algoritması açısından iyileştirilmiş çok katmanlı algılayıcı ağları geliştirilmiştir. Çok katmanlı algılayıcılar mimari açıdan doğrusal olmayan, aktivasyon fonksiyonuna sahip birden çok nöronun birbirine hiyerarşik olarak bağlandığı bir yapıya sahiptir. Ayrıca giriş verilerini işleyen bir veya daha fazla gizli katman içerirler. Geri yayılım algoritması gibi birçok öğrenme modeli de çok katmanlı ağların eğitimi üzerinde kullanılabilir (Şekil 2.14) [112].



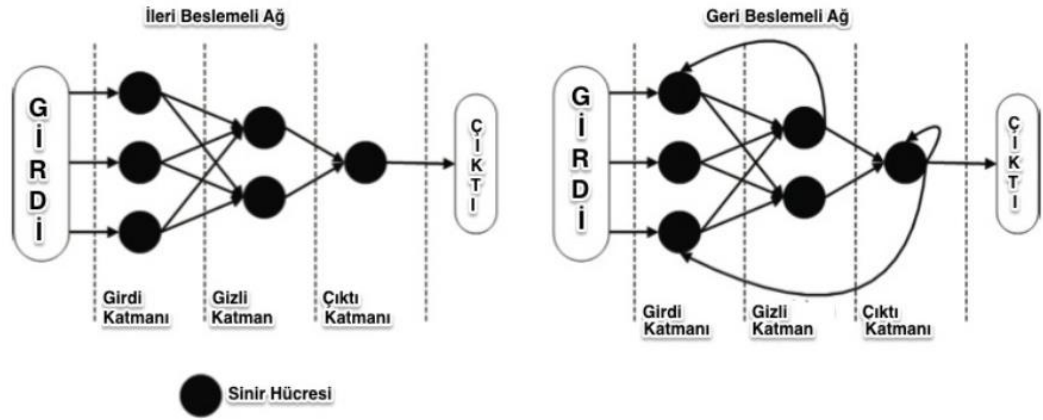
Şekil 2. 14 Çok katmanlı algılayıcı mimarisi [112].

2.8.1.3 İleri beslemeli ağlar

İleri beslemeli yapay sinir ağlarında hücreler katmanlar şeklinde düzenlenir. Giriş katmanından çıkış katmanına doğru tek yönlü bağlantı şeklinde sinyaller iletilir. Bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. İlk katman olan giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan ara (gizli) katmandaki hücrelere ileterek işlemeye başlar. Bilgi, ara ve çıkış katmanında işlenerek ağ çıkışı belirlenir (Şekil 2.15). Bu yapısı ile ileri beslemeli ağlar, doğrusal olmayan statik bir işlevi gerçekleştirir ve karmaşık veri desenlerini ve ilişkilerini öğrenerek çıktıları üretebilir [112, 116].

2.8.1.4 Geri beslemeli ağlar

Geri beslemeli yapay sinir ağlarında, ileri beslemeli ağlardan farklı olarak bir nöronun çıktısı sadece kendinden sonra gelen nöron katmanına girdi olarak verilmez. Bu ağlarda, çıkış katmanı ve ara katmanlardaki çıktılar bir önceki katmanları tekrar besleyebilir. Bu özelliği sayesinde mevcut ağ üzerinde ileri doğru hesaplamalar yapılırken geri bildirim ile geri yönde de hesaplamalar yapılmaktadır. Bu yapısı ile geri beslemeli yapay sinir ağları doğrusal olmayan dinamik bir davranış göstermektedir. Bu ağlar daha çok danışmansız öğrenme ile çözümlenen problemler için uygundur (Şekil 2.15)[112, 116, 124].

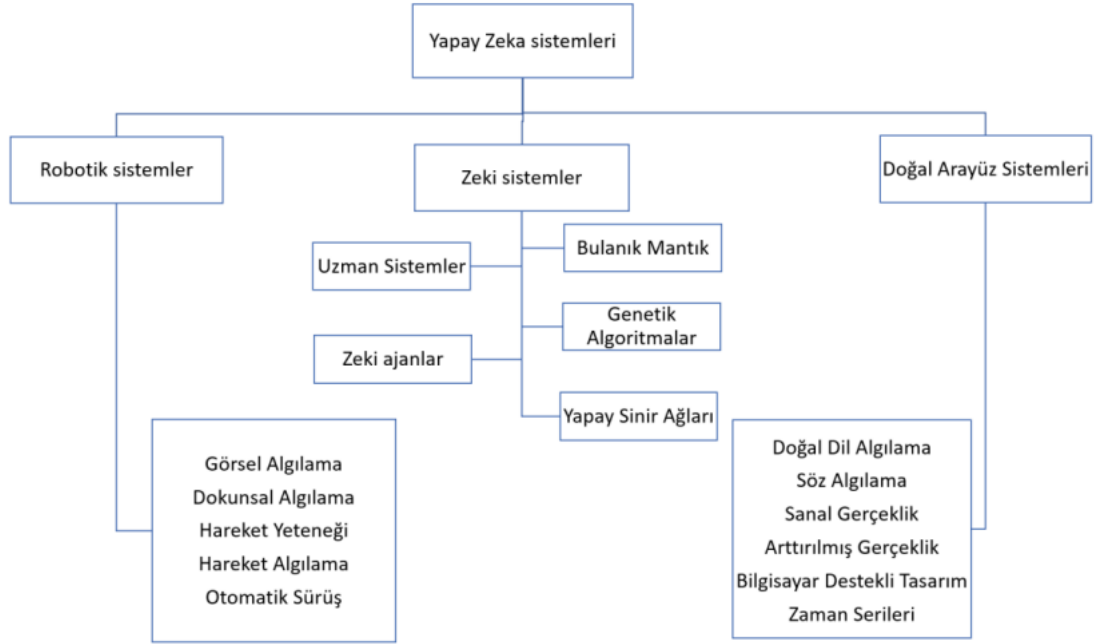


Şekil 2. 15 İleri ve geri beslemeli ağ örnekleri [125].

2.8.2 Yapay sinir ağlarının kullanım alanları

Yapay sinir ağlarının kullanıldığı alanlar; tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama, veri filtreleme olarak başlıklar altında toplanabilir. Banka kredilerinin değerlendirilmesi, risk analizleri, döviz kuru tahminleri, gibi finansal konularda; tıbbi sinyallerin analizi ve kanserli hücrelerinin analizi, hastalıkların belirlenmesi, kan tetkiklerinin sınıflandırılması gibi tıbbi işlemlerde; hedef izleme, nesnelere veya görüntüleri ayırma ve tanıma, askeri uçakların uçuş yörüngelerinin belirlenmesi, parmak izi tanıma, gibi konularda savunma sanayi uygulamalarında; planlama ve yönetim analizi, üretim sistemlerinin optimizasyonu, ürünlerin kalite analizi ve kontrolü, ürün analizi ve tasarımı gibi ticari üretim konularında ve meteorolojik yorumlama, robot sistemlerin kontrolü, karakter el yazısı

ve imza tanıma, resim işleme gibi daha pek çok işlem ve alanda yapay sinir ağları kullanılmaktadır (Şekil 2.16) [126, 127].



Şekil 2. 16 Yapay zeka uygulama alanları [128].

2.9 Derin Öğrenme

Geleneksel makine öğrenmesinin bazı karmaşık verilerin çözümlenmesinde yetersiz kalması, ham verileri düzenlemenin uzun sürmesi, zaman içerisinde yapay sinir ağı algoritmalarının geliştirilmesini ve derin öğrenme kavramının ortaya çıkmasını sağlamıştır. Derin öğrenme makinelerin dünyayı anlaması ve karmaşık problemlerin çözülmesi konusunda günümüzdeki en popüler yöntemdir [129]. Zaman içinde verilerin karmaşıklaşması kullanılan yapay zekâ tekniklerinin performanslarını arttırmaya yönelik çalışmaları arttırmıştır. Bu çalışmaların getirdiği bir sonuç olan derin öğrenme ile karmaşık verilerin işlenmesi ve analiz edilmesi mümkün hale gelmiştir [130]. Derin öğrenme, makine öğrenmesinin daha fazla sayıda ve karmaşık veriden daha hızlı sonuçlar üretebilen bir alt bölümüdür. Bu derin öğrenme algoritmalarını kullanarak bir bilgisayar görüntüleri nasıl sınıflandıracağını ve bir cümledeki kelimelere nasıl etiket atayacağını (anlamsal etiketleme) öğrenebilir. Derin öğrenme algoritmaları, büyük miktarlarda yapılandırılmamış veri kullanarak

karmaşık istatistiksel modelleri hesaplar ve açıkça programlanmadan sonuçları tahmin eder .

Derin öğrenme, yapay sinir ağları fikrine dayanan bir yaklaşım olup, büyük miktarda verinin çok sayıda nöron katmanından geçirilip karmaşık analizini gerçekleştirmek üzerine tasarlanmıştır [118, 131].

Veri sayısının gün geçtikçe artması ve çeşitlenmesi ayrıca farklı alanlardaki veya farklı kullanım durumlarındaki sorunları çözmek için çeşitli mimariler geliştirilmiştir [132].

Yaygın olarak kullanılan derin öğrenme mimarileri şunlardır:

- Evrişimli sinir ağları,
- Tekrarlayan sinir ağları,
- Derin oto kodlayıcılar,
- Kısıtlı Boltzmann makinesi,
- Uzun-Kısa süreli hafıza,
- Derin inanç ağlarıdır [132, 133].

Derin öğrenme kavramına ait temel derin öğrenme mimarisi ESA olarak kabul edilmektedir [134]. Derin öğrenme sistemleri, uzmanların önceden yorumlama gereksinimi olmadan verilerdeki bileşenleri otomatik olarak öğrenebilir. ESA, tıbbi görüntülemelerde en sık kullanılan derin öğrenme mimarileridir. Orijinal piksel bilgilerini kullanarak görüntü özelliklerini otomatik olarak çıkarabilen bu ağlar, sıklıkla dış hekimliğinde elde edilen görüntülerde de kullanılır [115].

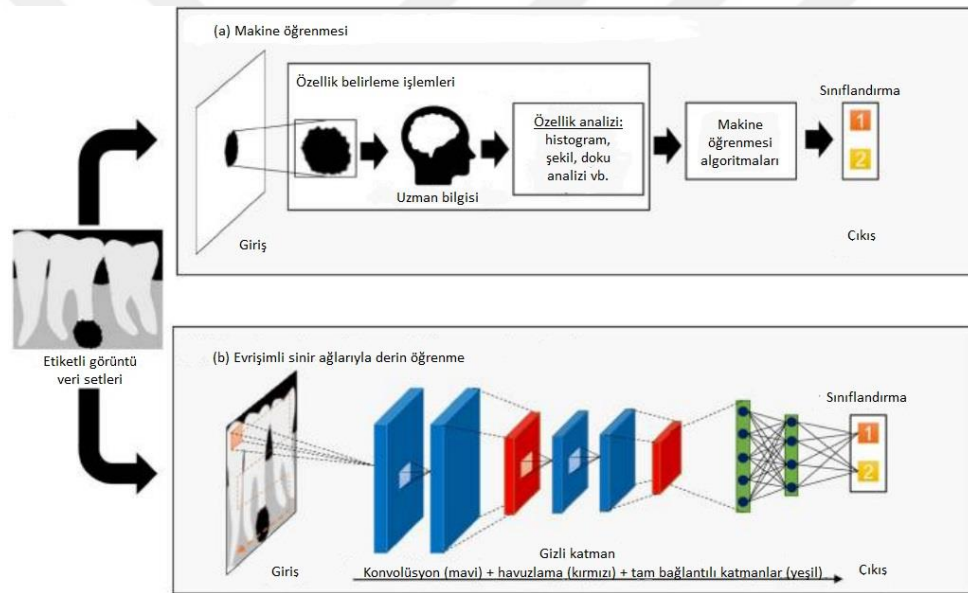
2.10 Evrişimli Sinir Ağları

Görüntü ve videodaki kalıpları tanımlamak için en yaygın kullanılan derin öğrenme mimarisi ESA'lardır. Geleneksel yapay sinir ağlarından evrimleşen ESA'lar, hayvanların görsel korteksinden ilham alan üç boyutlu bir sinir deseni kullanır.

ESA'lar, temel olarak nesne algılama, görüntü sınıflandırma, nesne tanımlama, öneri sistemleri, görüntü segmentasyonu, doğal dil işleme gibi problemlerde başarılı bir şekilde kullanılmaktadır.

ESA'lar yapay sinir ağlarının geliştirilmiş halidir. Yapay sinir ağlarındaki gizli katman sayılarının daha da artırılması sonucunda derinleşen ağ ESA olarak tanımlanabilir. Dolayısıyla ESA'ların gücü, katmanlarından gelmektedir. ESA'da bir nesnenin tanımlanması her bir katmanda o nesneye ait bir alt özelliğin bulunmasıyla mümkün olmaktadır. ESA, görüntünün kırmızı, yeşil ve mavi öğelerini aynı anda işlemek için üç boyutlu bir sinir ağı kullanır. Bu, geleneksel ileri beslemeli sinir ağları ile kıyaslandığında, bir görüntüyü işlemek için gereken yapay nöron sayısını önemli oranda azaltır.

ESA'lar, görüntüleri girdi olarak alır ve bu girdileri bir sınıflandırıcıyı eğitmek için kullanır. Matris çarpımı yerine ağ, "evrişim(konvolüsyon)" adı verilen özel bir matematiksel işlem kullanır [118, 121, 131, 135].



Şekil 2.17 Makine öğrenmesi ve evrişimli sinir ağlarıyla derin öğrenme [136].

2.10.1 Evrişimli sinir ağı katmanları

2.10.1.1 Giriş katmanı (input layer)

Giriş katmanı, ESA'larla öğrenme sürecinin başlangıç katmanı olarak bilinir. Görüntü işleme amacıyla kullanılan sinir ağlarında, genellikle görüntünün piksel matrisini temsil eder [137]. Bu katman için seçilen görüntü boyutu ağın performansını etkileyebilir. Görüntü boyutunun yüksek seçilmesi ile ağın derinliği artırarak bellek

ihtiyacını, eğitim süresini, görüntü başına düşen test süresini uzatabilir ancak bu durum ağın başarısını arttırabilir [134].

2.10.1.2 Evrişim katmanı (convolution layer)

Bu katman, ESA'nın temelini oluşturur ve görüntü özelliklerini belirlemede kullanılır. ESA'lar evrişim işlemini gerçekleştirmek için çeşitli filtrelere sahiptir. Evrişim işlemi, belirli bir filtrenin tüm görüntü üzerinde dolaştırılmasıyla gerçekleştirilir. Filtreler bir önceki katmandan gelen görüntüler üzerine evrişim işlemini uygulayarak çıkış verisini oluşturur. Düşük seviyeli evrişim katmanında basit özellikler (kenarlar, çizgiler ve köşeler gibi) çıkarılırken, daha sonraki yüksek seviyeli evrişim katmanlarında ise basit özelliklerin girişiyle daha detaylı özellikler belirlenir. Elde edilen çıktı, öznitelik haritası veya aktivasyon haritası olarak adlandırılır [134, 137].

2.10.1.3 Aktivasyon katmanı (ReLU)

Evrişim katmanlarından sonra gelen aktivasyon katmanı, non-linear dönüşüm işlemlerini gerçekleştirerek ağı öğrenme yeteneğini artıran bir birim olarak görev yapar. Bu katman aynı zamanda negatif evrişimsel sonuçları düzeltmek için kullanılır. Çeşitli aktivasyon fonksiyonları arasında, ESA'lar için en popüler olanı Rectified Linear Units Layer (ReLU) olarak bilinir. Bu katmanın kullanılması ağı daha hızlı öğrenmesini sağlar ve özellikle derin öğrenme modelleri için tercih edilen bir aktivasyon fonksiyonudur [134, 138].

2.10.1.4 Havuzlama katmanı (pooling layer)

Özellik haritaları ve aktivasyon haritalarının boyutlarını azaltmak için havuzlama katmanları kullanılır; bu sayede ağ küçük kaymalara ve bozulmalara karşı daha dayanıklı hale gelir. Ayrıca bu katmanın kullanımıyla bir sonraki ağ katmanlarının hesaplama yükü azalır ve sistemin ezberlemesi engellenmiş olur [134, 138].

2.10.1.5 Tam bağlı katman (Fully connected layer)

Tam bağlantılı katmanlar, kendinden önceki katmanlardaki tüm nöronlarla bağlantılıdır ve bu sayede önceki katmanlardan iletilen bilgileri birleştirebilir. Bu özelliği nedeniyle, yapay sinir ağlarının son katmanlarında kullanılırlar. Özellikle

sınıflandırma ve tahmin gibi karmaşık görevlerde, tam bağlantılı katmanlar sayesinde ağ daha hassas ve doğru sonuçlar elde edebilir [134, 137].

2.10.1.6 Seyreltme katmanı (DropOut)

Seyreltme katmanı, eğitim sırasında büyük verilere maruz kalan, çok katmanlı yapay sinir ağının ezberlemesini önlemek için kullanılır. Bazı nöronların bir sonraki katmana katkısını geçersiz kılan ve diğerlerini değiştirmeden bırakan bir katmandır. Bu, ağı daha genel hale getirerek, farklı girişlere daha iyi yanıt vermesini sağlar [138, 139]. Seyreltme katmanı, görüntü tanıma, doğal dil işleme ve makine çevirisi gibi çeşitli uygulamalarda kullanılmıştır [139].

2.10.1.7 Sınıflandırma katmanı (classification layer)

Tam bağlantılı katmandan sonra gelen bu katmanda sınıflandırma işlemi gerçekleştirilir. Bu katman sonrasında elde edilen veri değeri, sınıflandırılacak nesne sayısı ile aynıdır. Yani her sınıf için bir çıkış değeri elde edilir. Başarısı nedeniyle genellikle softmax sınıflandırıcı tercih edilir ancak farklı sınıflandırıcılar da bu katmanda kullanılabilir [134].

2.10.2 Evrişimli sinir ağının eğitilmesi

Eğitim süreci, öncelikle bir ESA modelinin oluşturulmasıyla başlar. Bu model; konvolüsyon, havuzlama, tam bağlantılı ve sınıflama katmanlarını içerir ve tasarımcıya ve mevcut çalışmaya göre katmanların sayısı ve sırası değiştirilebilir. Modelin başlangıç değişkenleri belirlenerek, filtre boyutu, filtre sayısı ve adım kayma miktarı gibi parametreler ayarlanır. Daha sonra eğitim setinden bir görüntü, oluşturulan modelde giriş verisi olarak kullanılır. Bu görüntü, katmanlardan geçerken her bir filtrenin ağırlığı ile piksel değerleri çarpılarak, çarpım işlemlerinin toplamları bir sonraki katmana iletilir. Bu süreç ileri besleme olarak adlandırılır. İleri besleme sürecinde elde edilen sonuç değeri ile hedef sonuç arasındaki fark alınarak toplam hata değeri hesaplanır. Hata değeri, geri yayılım algoritması adı verilen işlemle ağıdaki bütün ağırlıklara dağıtılır. Ağırlıkların güncellenmesi işlemine geri yayılım algoritması denilmektedir. Bu algoritmanın kullanılması ile ağırlıklar güncellenir ve ağı çıkışındaki toplam hata değeri düşürülmeye çalışılır. Hata değerinin düşürülmesi ve ideal sonuçlara yaklaşılması için ileri besleme ve geri yayılım algoritmaları tekrarlanır. Bu süreç, eğitim setindeki diğer görüntülerle de yinelenir. Eğitim süreci

boyunca ağ, veriler üzerinde doğru sonuçları üretmeyi öğrenir ve başarıyla görevini yerine getirebilir hale gelir [134, 140].

2.10.3 Derin öğrenme mimarilerinde hiperparametre kavramı

Hiperparametreler, ağ yapısını ve ağın eğitim sürecini belirleyen ve eğitim öncesinde kararlaştırılan değişkenlerdir. Hiperparametreler probleme ve kullanılan veri setine göre değişebilmektedir. Makine öğrenimi modellerinin performansını önemli ölçüde etkilerler.

Veri setlerinin boyutu, veri seti boyutunun küçük olması durumunda transfer öğrenme ve veri artırma (data augmentation) yöntemlerinin kullanılması, veri setlerinin çeşitliliği, verilerin gruplar halinde işlenmesi (mini-batch işlemi), kullanılan geri yayılım algoritmaları, optimizasyon algoritmalarının seçimi, eğitim adımlarının (epoch) sayısı, başlangıç ağırlık değerlerinin belirlenmesi, aktivasyon fonksiyonlarının seçilmesi (ESA'lar için genellikle ReLu), seyreltme değeri ve seyreltme uygulanacak katmanların belirlenmesi, modelin derinliğini belirleyen katman sayısı, katmanlardaki filtre sayısı, gizli katmanlardaki nöron sayısı gibi değişkenler ağın başarısını belirleyen önemli hiperparametrelerdir [141-144].

2.11 Derin Öğrenme Modelleri

2.11.1 LeNet

LeNet, Yann 1998 yılında LeCun ve arkadaşları tarafından tanıtılmış ilk konvolüsyonel yapay sinir ağı(CNN) olarak bilinmektedir. LeNet mimarisi öncelikle posta kodları gibi rakamları içeren karakter tanıma görevleri için geliştirilmiştir. Özellikle rakam tanıma alanında kullanılan ve tanınan MNIST veri tabanı ile birlikte çalıştırılarak başarılı sonuçlar elde etmiştir. Bu sayede LeNet, konvolüsyonel sinir ağlarının temelini oluşturmuş ve daha sonraki derin öğrenme modellerinin geliştirilmesine önemli katkı sağlamıştır [145].

2.11.2 AlexNet

AlexNet, 2012 yılında düzenlenen ImageNet büyük ölçekli görsel tanıma yarışmasında birinci olan derin öğrenme mimarisidir. Bu mimari, örüntü tanımda hata oranını %26'lardan %15'lere indirmeyi başarmıştır [146]. AlexNet'in bu büyük başarısı, derin öğrenme çalışmalarının dünya çapında daha popüler hale gelmesine

önemli ölçüde katkı sağlamıştır. Mimari, geniş ve derin konvolüsyonel sinir ağlarının önemini vurgulayarak önceki yöntemlerden daha iyi performans sergilemiş ve derin öğrenme alanında bir dönüm noktası olmuştur [134].

2.11.3 ZF Net

AlexNet' in 2012 yılında ImageNet yarışmasını kazanmasıyla derin öğrenme mimarileriyle ilgili yapılan çalışmalar hız kazanmıştır. 2013 yılında Matthew Zeiler ve Rob Fergus tarafından geliştirilen ZF Net mimarisi nesne tanımada hata oranını önemli ölçüde düşürerek %11.2'ye indirmiştir. ZF Net'in başarısı, derin öğrenme mimarilerinin nesne tanımada çok etkili olabileceğini göstermiştir. Günümüzde hala kullanılmakta olan ve birçok farklı alanda başarı elde etmiş olan bir mimaridir [133, 147].

2.11.4 VGGNet

Oxford üniversitesinde Simonyan ve Zisserman tarafından tasarlanan VGGNet mimarisi, ImageNet 2014 yarışmasında %7.3'lük hata oranı elde ederek iyi bir performans göstermiştir. Bu mimaride VGG16, VGG19 gibi konvolüsyon katman sayıları değişiklik gösteren altı farklı model seçeneği sunulmuştur. VGGNet, AlexNet'in mimarisine dayanmaktadır, ancak AlexNet'ten daha fazla konvolüsyon katmanı içermesi ve daha küçük filtre boyutları kullanması gibi bazı önemli farklılıkları vardır. VGGNet'in başarısı, derin öğrenme mimarilerinin nesne tanımada çok etkili olabileceğini göstermiştir [148].

2.11.5 GoogLeNet

GoogLeNet, 2014 yılında yapılan ImageNet yarışmasının galibi olmuştur. %5.7'lik hata oranı ile yüksek bir başarı göstermiştir. Mimarinin kompleks bir yapısı vardır. Inception modülü ile farklı boyutlarda filtreleme yaparak daha önceki derin öğrenme mimarilerinden farklı bir yapı ortaya koymuştur. Serinin ilk versiyonu olan GoogleNet inception v1 modeli, toplam 9 inception modülünden ve toplamda 100'den fazla katmandan oluşmaktadır. Inception modülü, farklı boyutlarda filtreleri tek bir katmanda birleştirerek, daha az katman kullanılarak daha fazla bilginin işlenmesini sağlar. Bu, GoogleNet'in daha hızlı ve daha verimli bir şekilde eğitilmesini sağlar [149].

2.11.6 ResNet

ResNet, Microsoft tarafından geliştirilen ve residual bloklardan oluşan çok katmanlı ve derin mimarisiyle, 2015 yılında ImageNet yarışmasında %3.6'lık hata oranıyla birinci olmuştur. Residual Block, önceki katmanlardan gelen bilgiyi sonraki katmanlara aktararak öğrenmeyi stabilize eder. Bu, ResNet'in daha derin ağlar oluşturmasına ve daha yüksek doğruluk elde etmesine olanak tanır. ResNet, görüntü sınıflandırma görüntü tanıma ve nesne tespiti gibi birçok alanda kullanılmaktadır [150, 151].

2.11.7 DenseNet

Her katmanın, ileri beslemeli bir şekilde diğer katmanlara doğrudan bağlı olduğu DenseNet mimarisi, 2017 yılında Gao Huang ve arkadaşları tarafından tanıtılan derin öğrenme ağıdır. Kaybolan gradyan sorunu, derin ağlarda meydana gelen bir sorundur. Ağın derinliği arttıkça, gradyanların büyüklüğü azalır. Bu, ağların öğrenmesini zorlaştırır. DenseNet mimarisi yoğun bağlantılı katmanlarıyla kaybolan gradyan sorununu hafifletmekte, özellik yayılımını güçlendirmekte ve özelliklerin yeniden kullanımını teşvik etmektedir [152].

2.11.8 U-Net

U-Net, 2015 yılında, bir biyomedikal görüntü segmentasyon mimarisi olarak önerilmiş ve başarılı olmuştur. Yazarlar, elektron mikroskobu görüntülerinde nöronal yapıları segmentlere ayırma veya ışık mikroskobu görüntülerinde hücre segmentasyonu gibi çeşitli segmentasyon zorluklarında mimariyi kullanarak diğer segmentasyon yöntemlerine göre yüksek doğruluk elde etmişlerdir [153].

U-net'in mimarisi 'U' harfine benzer bir şekle sahip olduğu için bu adı almıştır. Daralma ve genişleme adını alan iki ana bölümden oluşmaktadır. Daralma bölümü, klasik ESA mimarisindedir, aktivasyon fonksiyonu (ReLU) ve havuzlama katmanlarından oluşmaktadır. Genişleme bölümü ise U-net modelinin en önemli kısmıdır. Daralma bölümünden gelen özellikler genişleme bölümüne gönderilir ve bu bölümde genişletilerek girdi ile aynı boyutta ve çözünürlükte görüntü üretimi gerçekleştirilir. Daha yüksek doğruluk elde etmeyi amaçlar [154].

Ayrıca U-net başlangıçta iki boyutlu medikal görüntülemeler için tanıtılmıştır ancak zaman içerisinde üç boyutlu görüntüleme verilerinin artması ile mimari üzerinde çalışılmış ve V-Net olarak adlandırılan üç boyutlu görüntülerde kullanılan model geliştirilmiştir [155].

2.11.9 R-CNN

Gelişmiş derin öğrenme tekniklerinden olan bölge tabanlı CNN (R-CNN); makine öğrenimi, istatistik, bilgisayarla görme alanında ve bilgisayarlı görmenin alt dalları olan nesne algılama, görüntü kategorizasyonu ve görüntü segmentasyonunda başarılı bir şekilde kullanılmaktadır.

CNN bir görüntüdeki nesnenin sınıfını tanımlayabilir ancak nesnenin konumunu belirleyemez. Özellikle görüntüde birden fazla nesne olduğunda başarılı sonuçlar veremez. R-CNN ise seçici arama yöntemini kullanarak ilgilenilen bölgeyi (region of interest-RoI) tanımlar ve bu bölgeleri bir CNN kullanarak bunları ön ve arka plan olarak sınıflandırır. R-CNN, nesnenin konumunu belirleyebildiği ve birden fazla nesne içeren bir görüntüyü algılayabildiği için CNN tabanlı en iyi modellerden biri olarak kabul edilir.

2.11.10 You Only Look Once -YOLO

ESA yapısına sahip olan YOLO (You Only Look Once) hızlı ve küçük bir yapıya sahip bir nesne tanıma mimarisidir. YOLO, Joseph Redmon, Santosh Divvalai, Ross Girshick ve Ali Farhadi'nin 2016 yılında tanıtması ve OpenCV'nin People Choice Ödülünü kazanması ile büyük beğeni almıştır. YOLO'nun açılımı Türkçede "Sadece bir kez bakarsın" anlamına gelmektedir ve adından da anlaşılacağı üzere algoritma oldukça hızlı çalışmaktadır ve amacı tek seferde nesneyi tespit edebilmektir [156]. YOLO modeli, tek tek aşamalı ağ geçişlerinden farklı olarak ağın tek geçişinde hem nesne tanımlama hem de sınıflandırma işlemi yapabilmekte ve tek aşamalı dedektör olarak çalışabilmektedir. Bu mimariyi hızlı ve efektif kılan; görüntünün sadece sinir ağına iletilmesinin nihai nesne algılama sonucunun elde edilmesi için yeterli olmasıdır. Ayrıca güçlü bir genelleme yeteneği vardır [157].

YOLOv5'in önceki versiyonlarından en önemli farkları ana kütüphane olarak DarkNet yerine PyTorch kullanılması ve ana yazılım dili olarak da C yerine Python dilini kullanmasıdır [158, 159]. YOLOv5'in esas avantajı Python dilini

kullanmasından ileri gelmekte olup, PyTorch kütüphanesinin kullanılması ise daha hızlı eğitimin yapılabilmesini sağlamaktadır [159]. YOLOv5 modelinin mimarisinde de YOLOv4 modelinde olduğu gibi omurga, boyun ve kafa yapıları kullanılmıştır. Giriş görüntüleri omurga yapısı sayesinde özellik çıkarma işlemine tabi tutulur. Bu yapısı sayesinde elde edilenlerden bir özellik haritası oluşturulur. Özellik haritalarını kafa yapılarına aktaran boyun; aşağıdan yukarı, yukarıdan aşağı yönde birkaç yoldan oluşmaktadır. Tek aşamalı nesne tespiti işlemlerinde kafa yapılarında yoğun bir şekilde güven skoru ve başarı skoru elde edilmektedir [160]. Son resmi güncellemede YOLOv.7.0 yayınlanmıştır. Bu güncellemede transfer öğrenme tekniği kullanılarak Microsoft Common Objects in Context (MS COCO) veri kümesi ile ön eğitim uygulanmış segmentasyon modelleri kullanıma sunulmuştur [161].

2.12 Derin Öğrenme Kütüphaneleri

Son yıllarda derin öğrenme üzerine olan eğilimin artmasıyla birlikte, derin öğrenme modellerinin eğitimi ve başarı oranlarının artırılabilmesi amacıyla çeşitli programlama dillerinde (Java, C#, C++, Python vb.) birçok kütüphane dosyası oluşturulmuştur. Bu kütüphaneler, ESA' lar, ileri beslemeli ağlar, tekrarlayan sinir ağları gibi birçok derin öğrenme modeliyle birlikte kullanılabilir [162].

Derin öğrenme kütüphanelerinden bazıları şu şekildedir;

TensorFlow; Google araştırma grubu tarafından geliştirilen açık kaynak kodlu bir derin öğrenme kütüphanesidir. Tüm yazılım dilleri ile uyumlu bir şekilde çalışır ve herhangi bir yazılım dilindeki geliştiricinin kolayca kullanılmasını sağlar. Karmaşık olarak görünen modelleri esnek bir biçimde tasarlama olanağı tanımaktadır. Genel olarak görüntü işlemede sayısal hesaplamalar için tercih edilmektedir [162, 163].

Caffe; California Berkeley Üniversitesi'nde geliştirilen hızlı ve verimli bir kütüphanedir. Caffe, Python ve Matlab arayüzleri ve C++ programlama dili ile yazılmıştır. Önceden eğitilmiş modellere sahiptir bu nedenle, yeni modeller geliştirmek için zaman ve çaba harcamadan derin öğrenme modellerinin kullanılmasını kolaylaştırır [162, 163].

Theano; matematiksel ifadeleri, özellikle matris değerli olanları işlemek ve değerlendirmek amacıyla kullanılabilen bir kütüphanedir. Python yazılım diliyle geliştirilmiştir. Adını antik dönem filozofu olan Theano' dan almaktadır [163, 164].

Torch; Lua ve Python yazılım dilleriyle geliştirilmiş açık kaynak kodlu bir derin öğrenme kütüphanesidir. Bu kütüphane, karmaşık problemleri basitleştirip, problemin çözümüyle ilgili algoritmayı hızlı ve esnek bir yapıda hazırlayabilmektedir. Torch, görüntü işleme, ses işleme, video, resim gibi çeşitli alanlarda kullanılabilir [162].

Keras; Python yazılım dili ile yazılmış, TensorFlow ve Theano üzerinde çalışabilen üst düzey bir sinir ağı kütüphanes

idir. Keras'ın hızlı ve kolay prototipleme sağlaması, hem ESA'ları hem de tekrar eden ağı ve ikisinin kombinasyonlarını desteklemesi önemli avantajlarından [133, 163].

MXNet; verimliliğe ve esnekliğe odaklanan bir derin öğrenme kütüphanesidir. Python, R, Julia, Go, Javascript gibi birçok dili desteklemektedir. Çoklu dil desteğine sahip olduğu için yapılan çalışmayı farklı programlama dillerinde karşılaştırma olanağı sağlar [133, 162].

PyTorch; PyTorch, Facebook'un AI araştırma grubu tarafından Ekim 2016'da tanıtılan ve API (üst düzey uygulama programlama arayüzü) aracılığıyla derin öğrenme modelleri oluşturmayı kolaylaştıran Python tabanlı bir derin öğrenme çerçevesidir. PyTorch statik hesaplama grafikleri kullanan diğer derin öğrenme çerçevelerinin aksine, karmaşık mimariler oluşturmada daha fazla esneklik sağlayan dinamik hesaplama kullanır [165]. PyTorch, birçok kütüphaneyle entegre çalışır. Büyük, küçük birçok sinir ağında yüksek performans gösterir. PyTorch'daki bellek kullanımı, Torch veya bazı alternatiflere kıyasla son derece verimlidir ve daha büyük derin öğrenme modellerini eğitilmesini sağlar [166].


2.13 Derin Öğrenmede Temel Teknikler

Radyoloji alanında derin öğrenme uygulamalarında CNN'ler, sınıflandırma, nesne algılama ve segmentasyon işlevlerini gerçekleştirebilir (Şekil2.18).

Sınıflandırma, hastalıkların tanısından malignite türünün belirlenmesine kadar geniş bir uygulama yelpazesine sahip bir görevdir. Bilgi işlem gücündeki gelişmeler sayesinde, radyografik görüntü analizinde sınıflandırma problemlerini çözmek için daha karmaşık ve derin ESA modelleri geliştirilmiştir. Bu gelişmiş ESA modelleri, bilgisayarlı tomografi, manyetik rezonans görüntüleme ve röntgen gibi tıbbi görüntüleme yöntemleriyle elde edilen verileri değerlendirebilir.

Nesne algılama (tespit etme), radyografik görüntü analizinde lezyonların veya belirli anatomik yapıların bulunduğu bölgeleri tespit etmek için kullanılır. Nesne tespit etme işlemleri için kullanılan ESA'lar, sınıflandırma işlemleri için kullanılan ESA'larla benzerlik gösterir. Ayrıca, hastalıkların tespiti için ESA'lara regresyon veya bölge önerileri gibi ek görevleri yerine getirmek amacıyla bu özelliklere sahip birkaç katman eklenmiştir.

Segmentasyon, iki boyutlu radyografiler, bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRG) ve ultrason görüntüleri gibi çeşitli modaliteler kullanılarak elde edilen görüntülerdeki çeşitli anatomik yapıları veya lezyonları segmentlere ayırmak için bu yöntem kullanılır [136, 167-169].



Şekil 2. 18 Derin öğrenmede temel teknikler [136].

2.14 Diş Hekimliğinde Yapay Zekâ Kullanım Alanları

Son yıllarda kullanıcılara ait verilerin geometrik bir hızla artması, bu alanda toplanan verilerin çeşitlenmesi, verileri depolayacak yöntemlerin geliştirilmesi, yapay

zekâ ve alt dallarıyla ilgili yapılan çalışmaların hızla çoğalması gibi sebeplerden ötürü birçok alanda yapay zekâ uygulamaları kullanılmaya başlanmıştır.

Birçok sektörde olduğu gibi sağlık sektöründe de yapay zekâ çeşitli alanlarda kullanılmıştır. Bunlardan bazıları; hasta verilerinin analizi, kişiye özgü ilaç ve tedavi yöntemlerinin belirlenmesi, gerçek zamanlı önceliklendirme ve triaj, destekli veya otomatik teşhis ve reçeteleme, gebelikte sürecin yönetimi, erken teşhis, gen analizi ve düzenlenmesi, cihazların ve ilaçların etkinliklerinin saptanması, tıbbi görüntülemelerin değerlendirilmesi ve yorumlanması, anomali ve patolojilerin tespiti, hastalık riskinin değerlendirilmesi, prognoz tahmini gibi belirtilebilmektedir [122, 151, 170, 171].

Diş hekimliğinde ise yapay zekâ çoğunlukla geleneksel bazı yöntemleri modernize etmek amacıyla kullanılmaktadır. Genellikle teşhis ve veri yönetimini kolaylaştıran otomatik yazılım programları tasarlamak için yapay zekâ tabanlı sistemlerden yararlanılmaktadır [172].

Genellikle bu yazılımlar, uzmanlara daha isabetli kararlar verebilmeleri için yardımcı olan ve rehberlik eden klinik karar destek sistemleridir. Böylelikle bu sistemler daha iyi teşhis ve tedavi planlamasına katkı sunarken, prognozu tahmin etmek için de kullanılmıştır. Açıklama ve muhakeme sağlamadaki etkinlikleri nedeniyle bu sistemlere olan talep hızla artmaktadır [173, 174].

Yapay zekâ ve alt kolu olan derin öğrenme (deep learning) metodları kullanılarak diş hekimliğinin neredeyse tüm alanlarında çeşitli çalışmalar yapılmıştır. İki boyutlu görüntülemeler (periapikal, bitewing, sefalometrik, panoramik, grafiler), üç boyutlu görüntülemeler(KIBT) ve ağız içi fotoğraflar kullanılarak gerçekleştirilen çalışmaların bir kısmı şu şekilde sıralanabilir:

Diş tespiti, numaralandırma ve segmentasyon [175-182]

Çürük teşhisi [183-186]

Dişlerin kök-kanal morfolojilerinin değerlendirilmesi [187, 188]

Dental protez, restorasyon tespiti [189]

Periapikal patolojilerin değerlendirilmesi [190-192]

Periodontal kemik kaybı tespiti [193-197]

Mandibular kanal tespiti ve deęerlendirilmesi [198-201]

Gömülü dişlerin tespiti (süpernümerer dişler, üçüncü molar dişler) [5, 202]

Diş çekim zorluğu tahmini (mandibular üçüncü molar dişler için) [4]

Kist-tümör lezyonlarının tespiti [203-206]

Maksiller sinüslerin deęerlendirilmesi [207-209]

Panoramik röntgenler üzerinden osteoporoz teşhisi [210, 211]

Dental implantların tespiti ve sınıflandırılması [212-214]

Sefalometrik analiz [215, 216]

Oral bölge kanserlerinde yapılan deęerlendirmeler [217-219]

3. MATERYAL METOD

Bu çalışma için Bezmialem Vakıf Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu'na başvurulmuş ve çalışma E-54022451-050.05.04-111201 numaralı belge ve 2022/394 karar numarası ile onaylanarak; Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Kliniği'nde gerçekleştirilmiştir.

Bu tez çalışmasında; ESA'lara dayalı bir yapay zekâ modeli olan Craniocatch (Eskişehir, Türkiye) uygulaması ile daimi dentisyonda çekim endikasyonu olan mandibular 1. molar dişlerin ideal çekim zamanının belirlenmesinde; mandibular 2. Molar dişlerin Demirjian metoduna göre gelişim safhalarının panoramik radyografiler üzerinden yapay zekâ programına öğretilmesi ve buna bağlı olarak ideal çekim zamanının yapay zekâ uygulaması tarafından belirlenebilirliği değerlendirilmiştir.

3.1 Görüntülerin Seçilmesi

Bu tez çalışmasında, Bezmialem Vakıf Üniversitesi, Diş Hekimliği Fakültesi, Ağız Diş ve Çene Radyolojisi Anabilim Dalı 2014-2023 yıllarını kapsayan panoramik radyografi arşivi kullanılmıştır.

Arşiv içerisinde daimi mandibular 1. ve 2. molar dişleri bulunan ve dahil edilme kriterlerini içeren fakat dışlanma kriterlerini içermeyen panoramik röntgenler veri setine eklenmiştir.

Dahil olma kriterleri;

- Optimum şartlar altında çekilmiş panoramik radyografiler
- 3 ile 20 yaş arasındaki kişilere ait panoramik radyografiler
- 36 ve 37 numaralı dişleri mevcut olan hastalara ait radyografiler
- 46 ve 47 numaralı dişleri mevcut olan hastalara ait radyografiler
- Herhangi bir lezyon veya dental anomaliye sahip olmayan 37 ve 47 numaralı dişlerin bulunduğu radyografiler

Dışlanma kriterleri;

- Optimum şartlar altında çekilmemiş (değerlendirmeye engel olan artefakta sahip panoramik radyografiler) panoramik radyografiler
- 20 yaş üstündeki kişilere ait radyografiler
- 37 veya 47 numaralı dişlerin eksik olduğu hastalara ait radyografiler
- 36 veya 46 numaralı dişlerin eksik olduğu hastalara ait radyografiler
- Herhangi bir lezyonla ilişkili olan 37 ve 47 numaralı dişlerin bulunduğu radyografiler
- Dental anomaliye sahip 37 ve 47 numaralı dişlere sahip radyografiler

3.2 Radyografik Veri Setlerinin Elde Edilmesi

Tez çalışmamızın veri seti, Planmeca Promax 2D (Planmeca, Helsinki, Finland) cihazı ile; 68 kVp, 16 mA ve 13 s. parametreleri ile çekilen panoramik radyografiler retrospektif olarak taranarak oluşturulmuştur.

Veri setine dahil edilen panoramik görüntüler kimlik bilgilerini içermeyecek bir şekilde “jpeg” formatıyla kaydedilmiştir. Röntgenlerdeki mevcut 2. molar dişler sınıflandırılma gruplarına göre ayrılmış ve toplamda 1106 panoramik radyografi kullanılmıştır. Veri setinde, mandibular ikinci molar dişlerin gelişim aşamaları “Demirjian metodu” kullanılarak değerlendirilmiş ve 8 alt sınıfa ayrılmıştır.

Demirjian Metodu:

Diş gelişiminin A’dan H’a kadar 8 aşaması mineralizasyonun sınırlarına göre aşağıdaki Şekil 3.1- 3.8’de açıkça tanımlanmıştır:




Şekil 3. 1 Demirjian safha A.



Şekil 3. 2 Demirjian safha B.



Şekil 3. 3 Demirjian safha C.



Şekil 3. 4 Demirjian safha D.



Şekil 3. 5 Demirjian safha E.



Şekil 3. 6 Demirjian safha F.



Şekil 3. 7 Demirjian safha G.



Şekil 3. 8 Demirjian safha H.


Hazırlanan veri setleri CranioCatch yazılımına (Eskişehir, Türkiye) aktararak projeler oluşturuldu ve etiketlemeye hazır hale getirildi. Bir görüntüdeki alanların tanımlanması ve nesnenin tanımlanan hangi bölgeye ait olduğunun belirlendiği işlem olan etiketleme işlemi, proje içerisindeki 1106 panoramik radyografiye uygulandı. Panoramik radyografilerdeki ikinci büyük azı dişler; 3 yıllık deneyime sahip uzmanlık öğrencisi ve 6 yıllık deneyime sahip Ağız, Diş ve Çene Radyolojisi uzmanı tarafından CranioCatch (Eskişehir, Türkiye) yazılımı kullanılarak etiketlendi. İki hekimin teşhisinin eşleşmediği tüm panoramik radyografiler veri setinden çıkarıldı.

Radyografilerden yapay zekâ sistemlerinin geliştirilebilmesi için eğitim, doğrulama ve test seti şeklinde veri setleri oluşturuldu. Model-algoritma oluşturulduktan sonra sistem performansı değerlendirildi.


Panoramik görüntüler üzerinde etiketleme; dişlerin dış sınırlarının serbest çizim tekniğiyle belirlenerek çizilmesi (segmentasyon tekniği, poligon yöntemi) ve ilgili bölgenin bounding box veya detection olarak adlandırılan yöntemle dikdörtgen şeklinde tespit edilmesiyle gerçekleştirildi. Segmentasyon tekniğinde; dişlerin kuron oluşumu tamamlanincaya kadar yalnızca dişlerin folikülü işaretlenirken, kök oluşumunun başlamasıyla birlikte diş sert dokusu etrafında işaretleme yapıldı (Şekil 3.9). Detection ise; ilgili dişin dış sınırlarını içine alan olabilecek en küçük kutu işaretlendi (Şekil 3.10).

Detection, segmentasyondan daha basit bir tekniktir. Segmentasyon, görüntüdeki her pikselin bir sınıfa atanmasını gerektirirken, Detection sadece nesnenin konumunu ve boyutunu tanımlar.

Dişler, FDI (Federation Dentaire Internationale; Dünya çapında diş hekimliğinde daimi diş numaralandırmada kullanılan sistem) sistemine göre sınıflandırıldı. Etiketleme için 37 ve 47 numaralar kullanıldı. Veri setlerindeki alt gruplara (Demirjian A-H) uygun olarak etiketlemeler tamamlandı.



Şekil 3. 9 Sistem üzerinde segmentasyon yöntemiyle etiketleme yapılması.



Şekil 3. 10 Sistem üzerinde bounding box/area detection yöntemiyle etiketleme yapılması.

3.3 Derin Öğrenme Mimarisi

Çalışmamızda derin öğrenme, PyTorch kütüphanesi ve Python açık kaynak programlama dili (v.3.6.1; Python Software Foundation, Wilmington, DE, ABD) kullanılarak gerçekleştirildi. Dişlerin Demirjian metoduna göre safhalarının belirlenmesinde, segmentasyon ve detection için başarılı sonuçlar veren hızlı ve küçük bir mimari olan YOLOv5 kullanıldı.

3.4 Model Geliştirilmesi

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


3.5 Eğitim Aşaması

Yapay zekâ sistemlerinin geliştirilmesinde ve başarı göstermesinde veri kümesinin büyüklüğü doğrudan etkilidir. Çalışmamızın 37 ve 47 numaralı dişlerin gelişim aşamalarının hem tespitinde ve hem de segmentasyon kısmında en uygun ESA algoritmasının ağırlık faktörlerini tahmin etmek ve üretmek için mevcut veri seti; eğitim, doğrulama ve test seti şeklinde 3 gruba ayrıldı (Şekil 3.11). Eğitim ve doğrulama veri setleri bu ESA algoritmaları için optimal ağırlık faktörlerini tahmin etmek ve oluşturmak için kullanıldı.

Eđitim veri seti: Modelin eđitimi iin kullanılan veri setidir.

Dođrulama veri seti: Geliřtirme seti olarak da bilinen bu veri seti modelin hiperparametrelerini ayarlamak ve genel performansını deđerlendirmek iin önemlidir. Modelin eđitiminden bađımsız olan ve bu sure boyunca modelin gormemesi gereken rnekleri ifade eder.

Test veri seti: Modelin nihai performansını tarafsız olarak deđerlendirmek iin kullanılan ayrı bir veri setidir. Model daha nce gormediđi veri kümesi zerinde test edilir.



řekil 3. 11 Veri setleri dađılımı.

Model bir kere seildikten sonra, tm veri seti zerinde eđitilir ve grlmemiř test setinde bařarısı deđerlendirilir.

Demirjian metoduna gre diř geliřim safhalarının sınıflandırılması iin alıřılan veri seti 1106 adet panoramik radyografiden oluřmaktadır. Veri setinin yaklaşık olarak %10'u test, %10'u dođrulama, %80'i de eđitim veri seti olarak ayrılmıř olup, Tablo 3.1'de sayısal olarak belirtilmiřtir.

Tablo 3. 1 Detection/bonding box ve segmentasyon iin veri seti sınıflandırması.

Eđitim veri seti	885 grnt	1686 etiket
Dođrulama veri seti	111 grnt	211 etiket
Test veri seti	110 grnt	203 etiket

YOLOv5 modelinin eđitimi "High" hiperparametresi ile 500 epoch (eđitim tur sayısı) yapılarak gerekleřtirilmiřtir.


Tablo 3. 2 Demirjian metodu diř gelişim safhaları (A-H) veri seti sayıları.

Demirjian metodu safhaları	Veri setine dahil edilen toplam panoramik radyografi sayıları	Panoramik radyografi üzerinde yapılan toplam etiketleme sayıları
A	95	150
B	91	150
C	84	150
D	81	150
E	84	150
F	95	150
G	94	150
H	85	150

Ayrıca 396 adet panoramik radyografi A-H grupları randomize olarak içerecek şekilde dahil edilmiş ve üzerinde 786 adet etiketleme yapılmıştır.

3.5.1 Demirjian Metodu Sınıflandırma Eğitimleri


Özellikle 6 yaşına kadar olan çocuklarda, üst çenenin kemik yapısı nedeniyle radyograflardan kaliteli görüntü elde edilememektedir. Alt çenedeki dişler ise panoramik radyograflarda daha net görüntü vermektedir. Bu sebeple, çalışmada sağ ve sol alt çenedeki dişler arasında yüksek uyumluluk tespit edildiğinden 37 ve 47 numaralı dişlerin radyografik incelenmesi yapılmış ve Demirjian metoduna göre A'dan H'ye segmentasyon ve detection ile etiketlemeleri yapılmıştır (Şekil 3.12-19).




Şekil 3. 12 Demirjian safha A; detection ve segmentasyonla etiketlenmiş.




Şekil 3. 13 Demirjian safha B; detection ve segmentasyonla etiketlenmiş.



Şekil 3. 14 Demirjian safha C; detection ve segmentasyonla etiketlenmiş.



Şekil 3. 15 Demirjian safha D; detection ve segmentasyonla etiketlenmiş.




Şekil 3. 16 Demirjian safha E; detection ve segmentasyonla etiketlenmiş.



Şekil 3. 17 Demirjian safha F; detection ve segmentasyonla etiketlenmiş.



Şekil 3. 18 Demirjian safha G; detection ve segmentasyonla etiketlenmiş.



Şekil 3. 19 Demirjian safha H; detection ve segmentasyonla etiketlenmiş.

3.6 İstatiksel Analiz

Modellerin başarılarının değerlendirilmesi, hata matrisi (karışıklık matrisi, confusion matrix) kullanılarak yapıldı. Hata matrisi, bir sınıflandırma sistemi tarafından yapılan gerçek ve tahmin edilen sınıflandırmaları özetleyen matris formatında bir tablodur. Sistemlerin performansı matristeki veriler kullanılarak değerlendirilir [220].

Demirjian metoduna göre dişlerin gelişim aşamalarını belirleme çalışmalarında, hata matrisi ile birlikte, Kesinlik–Duyarlılık eğrisi (Precision–Recall Curve/PR) oluşturuldu.

3.6.1 Hata matrisi hesaplama prosedürü

Hata matrisi ikili sınıflandırma görevlerinde gerçek değerler ile sınıflandırıcının tahmin ettiği değerleri gösteren, 2x2 boyutunda matris şeklinde bir tablodur. Hata matrisinde sistemlerin performansı matristeki veriler kullanılarak değerlendirilir. Tahmin edilen değerlerin gerçek değerlerle karşılaştırması yapılabilmektedir [220].

Tablo 3. 3 İkili sınıflandırma için karışıklık matrisi.

	Tahmini değeri: HAYIR	Tahmini değeri: EVET
Gerçek değeri: HAYIR	DN	YP
Gerçek değeri: EVET	YN	DP

Modelin başarısını değerlendirmek için kullanılan metrikler şu şekildeydi:

Doğru pozitif (DP) : Diş durumu doğru tespit edildi.

Yanlış pozitif (YP) : Diş durumu yanlış tespit edildi.

Yanlış negatif (YN) : Diş durumu tespit edilemedi.

Çalışmamızda doğru negatif (DN) metriği kullanılmadı.

3.7 Performans Değerlendirme

Doğruluk (accuracy): Doğru sınıflandırılan gözlem sayısının toplam gözlem sayısına olan oranıdır. Modelin değerlendirilmesinde kullanılmasına rağmen tek başına yeterli bir parametre değildir.

$$\text{Doğruluk oranı: } DP+DN / DP + DN + YP + YN$$

Duyarlılık (recall, sensitivite): Gerçek değeri pozitif olan gözlemlerin ne kadarının pozitif olarak tahmin edildiğini gösterir. Doğru pozitif örneklerin oranını hesaplamak için kullanılır. Yalancı negatifliklerin çok olduğu durumlarda duyarlılık (recall) değeri düşük çıkmaktadır dolayısıyla model seçiminde yüksek duyarlılık değerine sahip

parametreler seçilmelidir. Hesaplanması için kullanılan matematiksel işlem şu şekildedir;

$$Duyarlılık = DP / (DP + YN)$$

Kesinlik değeri (precision): Tahmin edilen pozitif gözlemler içerisinde ne kadarının doğru tahmin edildiğini gösterir dolayısıyla doğru tahminlerin ne kadar kesin olduğunu belirtir. Yalancı pozitifliklerin az olması modelin seçiminde önemli olacağından kesinlik değerinin yüksek olması istenmektedir. Hesaplanması için kullanılan matematiksel işlem şu şekildedir;

$$Kesinlik = DP / (DP + YP)$$

F1 skoru: Kesinlik ve duyarlılık sonuçlarının ağırlıklı (harmonik) ortalamasını göstermektedir. Sadece yalancı pozitif ve yalancı negatif değil, tüm hata maliyetlerini içeren bir değerlendirme aracıdır. Hesaplanması için kullanılan matematiksel işlem şu şekildedir;

$$F1\ skoru = 2 \times (Duyarlılık \times Kesinlik) / (Duyarlılık + Kesinlik)$$

Birleşim üzerinden ortalama kesişme (IoU): Gerçek pozitifleri, yanlış pozitifleri ve yanlış negatifleri kullanan standart bir değerlendirme yöntemidir. IoU metriği, önerilen yöntemin sonucu ile dış segmentasyonundaki temel gerçeklik alanı arasındaki örtüşen bölgeyi gösterir. Bu alan %50'den büyük olduğunda DP, küçük olduğunda YP olarak kabul edilir.

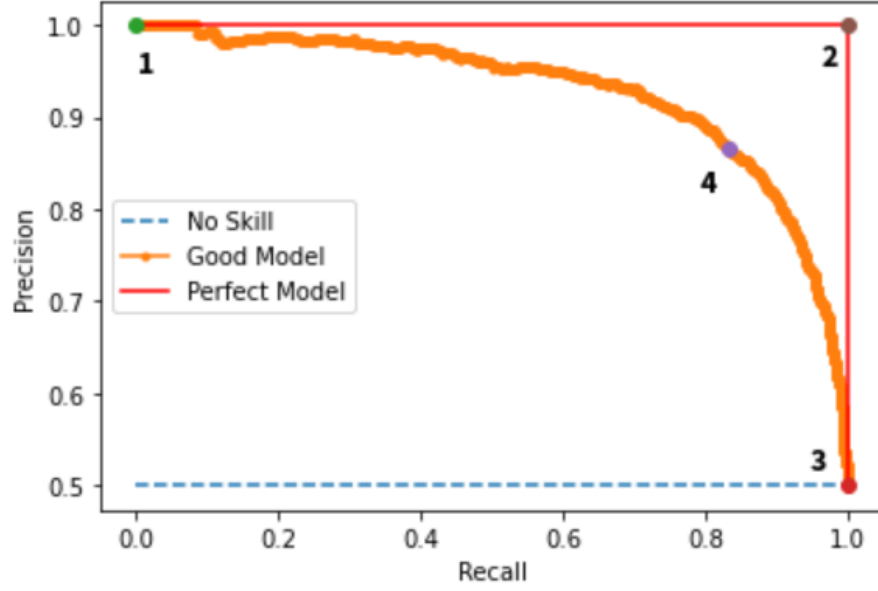
IoU'yu hesaplamak için kullanılan denklem şu şekildedir:

$$IoU: DP / (DP + YN + YP)$$

3.8 Kesinlik- Duyarlılık Eğrisi (PR Eğrisi, Precision-Recall Curve)

Kesinlik – Duyarlılık (PR) eğrileri sınıf dağılımında büyük bir çarpıklığa sahip görevler için ROC eğrilerinin bir alternatifi olarak belirtilmiştir. ROC eğrilerinin y ekseninde PR eğrilerinin x ekseninde aynı değeri yani doğru pozitif oranı

(TPR=Duyarlılık değeri) vardır. Bu eğrilerin görsel temsili eğrilerin arasındaki önemli bir farkı oluşturur. PR eğrilerinde, eğrinin sağ üst köşeye yaklaşması başarı oranının arttığını gösterir (Şekil 3.20) [221-223].



Şekil 3. 20 Kesinlik-Duyarlılık eğrisi.

4. BULGULAR

Çalışmaya dâhil edilen 1106 panoramik radyograf 3-20 yaş grubunda 545 erkek ve 562 kadın hastaya aittir. Bu radyograflardan Demirjian metodu kullanılarak sağ ve sol mandibular ikinci büyük azı dişin radyografteki mineralizasyon aşamaları değerlendirilerek Demirjian ve ark (1973) tarafından oluşturulan Şekil 3.12-3.19'daki A-H mineralizasyon aşamaları ile eşleştirilmiştir.

Çalışmamızda; panoramik radyografi görüntüleri üzerinde, derin öğrenme yöntemlerinden biri olan YOLOv5 modelinin Demirjian metoduna göre diş gelişim aşamalarını belirlemedeki başarısı araştırılmıştır. Proje oluşturma aşamasında 1106 panoramik radyograf üzerinden 37 ve 47 numaralı dişlerin etiketlenmesi ile toplamda 8 adet veri seti sınıfı oluşturulmuştur.

4.1 Demirjian Metodu Sınıflandırma Sonuçları

YOLOv5 modelinin 37 ve 47 numaralı dişler üzerinden Demirjian metoduna göre A-H diş gelişim aşamalarını detection ve segmentasyon için ayrı ayrı olarak tahmin etmedeki doğru pozitif (DP), yanlış pozitif (YP) ve yanlış negatif (YN) değerleri Tablo 4.1'de verilmiştir. Bu değerler intersection over union (IoU) threshold değeri %50 olarak seçildiği zamana göre elde edilmiştir. Veri olarak girilen görüntü boyutları 1280x640 piksel olan 1106 radyograf üzerinde 2100 adet etiketleme yapılmıştır. Bu verilerin yaklaşık %10'u test aşamasında, %10'u doğrulama aşamasında ve %80'i ise eğitim aşamasında kullanılmıştır. YOLOv5 modeli ile 500 epoch (eğitim tur sayısı) yapılarak eğitim gerçekleştirildi. Öğrenme hızı (learning rate) değeri ise 0.01'di. Hiperparametre olarak modelin kendisinde bulunan 'high' hazır parametresi kullanılmıştır. Modelde kullanılan veri arttırma (augmantasyon) teknikleri Flip Up-Down, HSV-Hue, Hue-Saturation, HSV-Value, Mosaic ve kütüphaneler ise Pytorch, Opencv, Numpy, Pandas, Torch Vision, Torch, Tensorboard, Seaborn'dur.

Tablo 4. 1 Detection ve segmentasyon için DP, YP ve YN değerleri.


	Doğru Pozitif (DP)	Yanlış Pozitif (YP)	Yanlış Negatif (YN)
Detection	201	18	2
Segmentasyon	200	17	3

YOLOv5 modelinin 37 ve 47 numaralı dişler üzerinden Demirjian metoduna göre A-H diş gelişim aşamalarını tahmin etmedeki duyarlılık, kesinlik ve F1 skor değerleri Tablo 4.2’de verilmiştir.

Tablo 4. 2 YOLOv5 modelinin detection ve segmentasyon için duyarlılık, kesinlik ve F1 skorları.


	Duyarlılık (DP/(DP+YN))	Kesinlik (DP/(DP+YP))	F1 skoru (2DP/(2DP+YP+YN))
Detection	0.990147783	0.917808219	0.952606635
Segmentasyon	0.985221675	0.921658986	0.952380952

Eğitim aşamasında 1186 tane etikete sahip 885 radyografik görüntü kullanılmıştır. Daha sonra doğrulama aşamasında 211 tane etikete sahip 111 radyografik görüntü kullanılmıştır. Modelin güzel çalıştığı anlaşıldıktan sonra 203 tane etikete sahip 110 radyografik görüntü üzerinde test yapılmıştır. Testin sonucunda elde edilen ortalama kesinlik değerlerinin ortalaması (mAP) tespit etme (detection) aşamasında 0.93813 olarak ve segmentasyon aşamasında 0.94136 olarak bulunmuştur. Bu değerler Tablo 4.1’de verilen doğru pozitif (DP), yanlış pozitif (YP) ve yanlış negatif (YN) sonuçlarından ayrıca hata matrisi (confusion matrix) değerleri dikkate alınarak hesaplanmıştır. Yanlış bulunan görüntüler incelendiğinde yanlış tahmin edilen safhaların komşu safhalar arasında olduğu gözlemlenmiştir. Örneğin, modelimiz 37 G safhasında tespit edilmesi gereken bazı görüntüleri komşusu olan 37 H veya 37 F safhasında tahmin etmiştir. Benzer durum hem detection hem segmentasyon için diğer safhalarda da gözlemlenmiştir. Bu durumun detayları her bir sınıf için Şekil 4.1’de verilen hata matrisinde incelenebilir.



Şekil 4. 1 YOLOv5 modelinin detection verilerinden elde edilen normalize edilmiş hata matrisi.

Şekil 4.1’de verilen normalize edilmiş hata matrisi değerlerine bakıldığı zaman 37 numaralı dişte B, C, E, H sınıflarında ve 47 numaralı diş için A, D ve E sınıflarında model tüm verileri doğru tahmin etmiştir. En yüksek yanlış tahmin 47 numaralı dişin F safhasında görülmektedir. Hata matrisi grafiğinde background olarak belirtilen kısım randomize olarak seçilen safhalardan belirlenen 396 radyografi üzerinden yapılan 786 etiketlemenin değerlerini göstermektedir.




Şekil 4. 2 YOLOv5 modelinin detection için Kesinlik-Duyarlılık eğrisi.


Şekil 4.2. de sol tarafta kesinlik-duyarlılık eğrisi (precision-recall curve), sağ tarafta her bir sınıfa ait AUC değerleri verilmiştir. Eğrinin tüm sınıflar için ortalama AUC değeri 0.938'dir. Bu değer modelin oldukça hassas çalıştığını gösterir. Modelin her bir sınıf için ne kadar hassas çalıştığı grafiğin sağında bulunan tablodaki değerler incelendiğinde en hassas sonuç 0.990 AUC değeri ile 47 D sınıfına ait olurken, en düşük hassasiyete sahip sınıf 0.862 AUC değeri ile 37 B sınıfıdır.

Tablo 4. 3 Detection için Kesinlik-Duyarlılık eğrisi sonuçları.

Detection	Kesinlik-Duyarlılık Eğrisi AUC Değeri
37 A	0.922
37 B	0.862
37 C	0.897
37 D	0.920
37 E	0.988
37 F	0.911
37 G	0.928
37 H	0.974
47 A	0.988
47 B	0.917
47 C	0.952
47 D	0.990
47 E	0.995
47 F	0.902
47 G	0.902
47 H	0.963



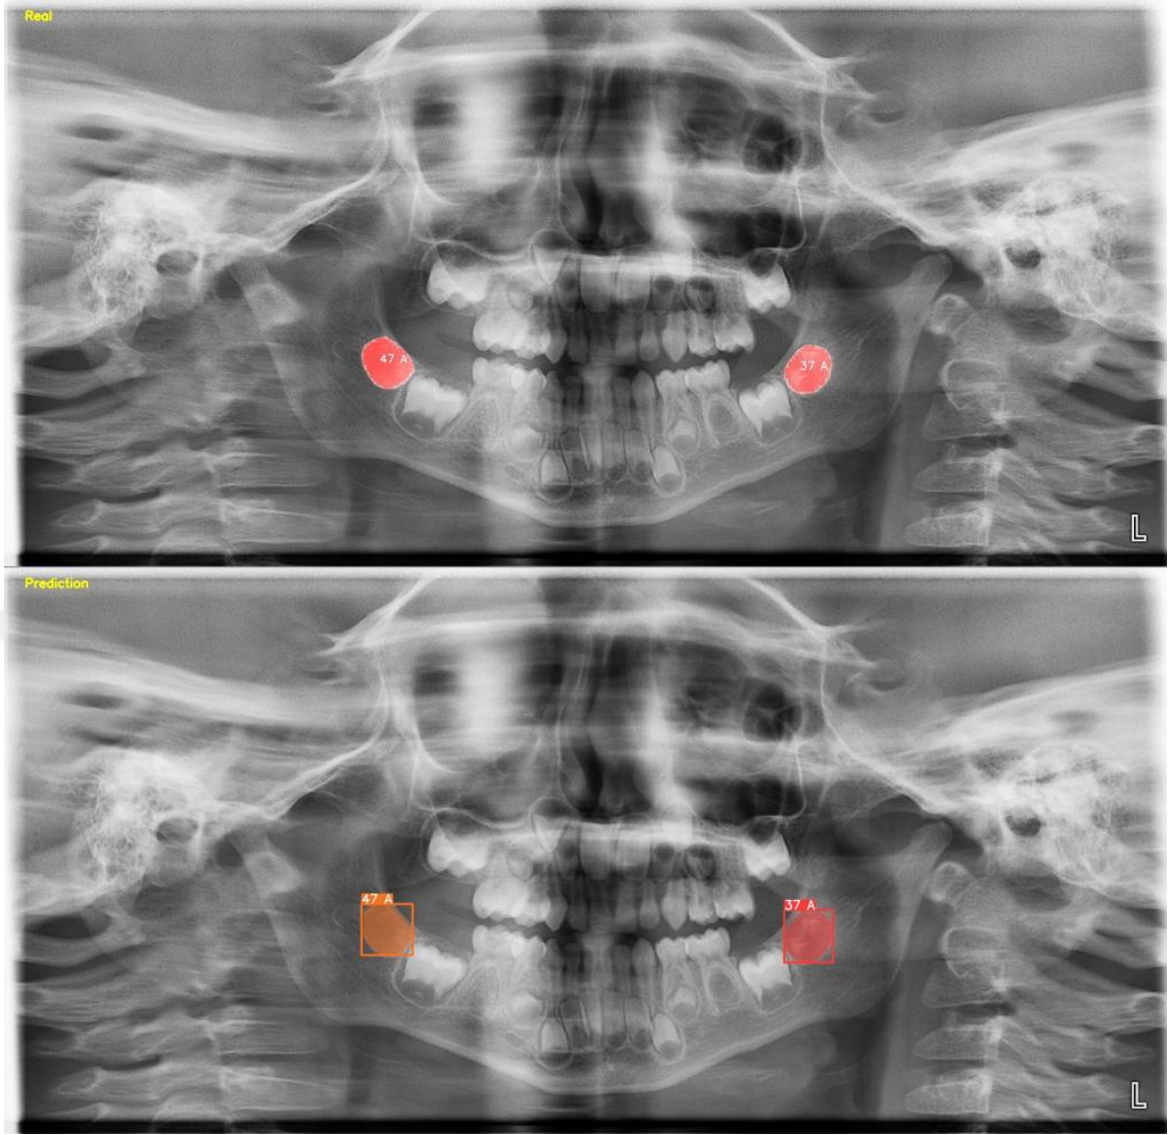
Şekil 4. 3 YOLOv5 modelinin segmentasyon verilerinden elde edilen normalize edilmiş hata matrisi.



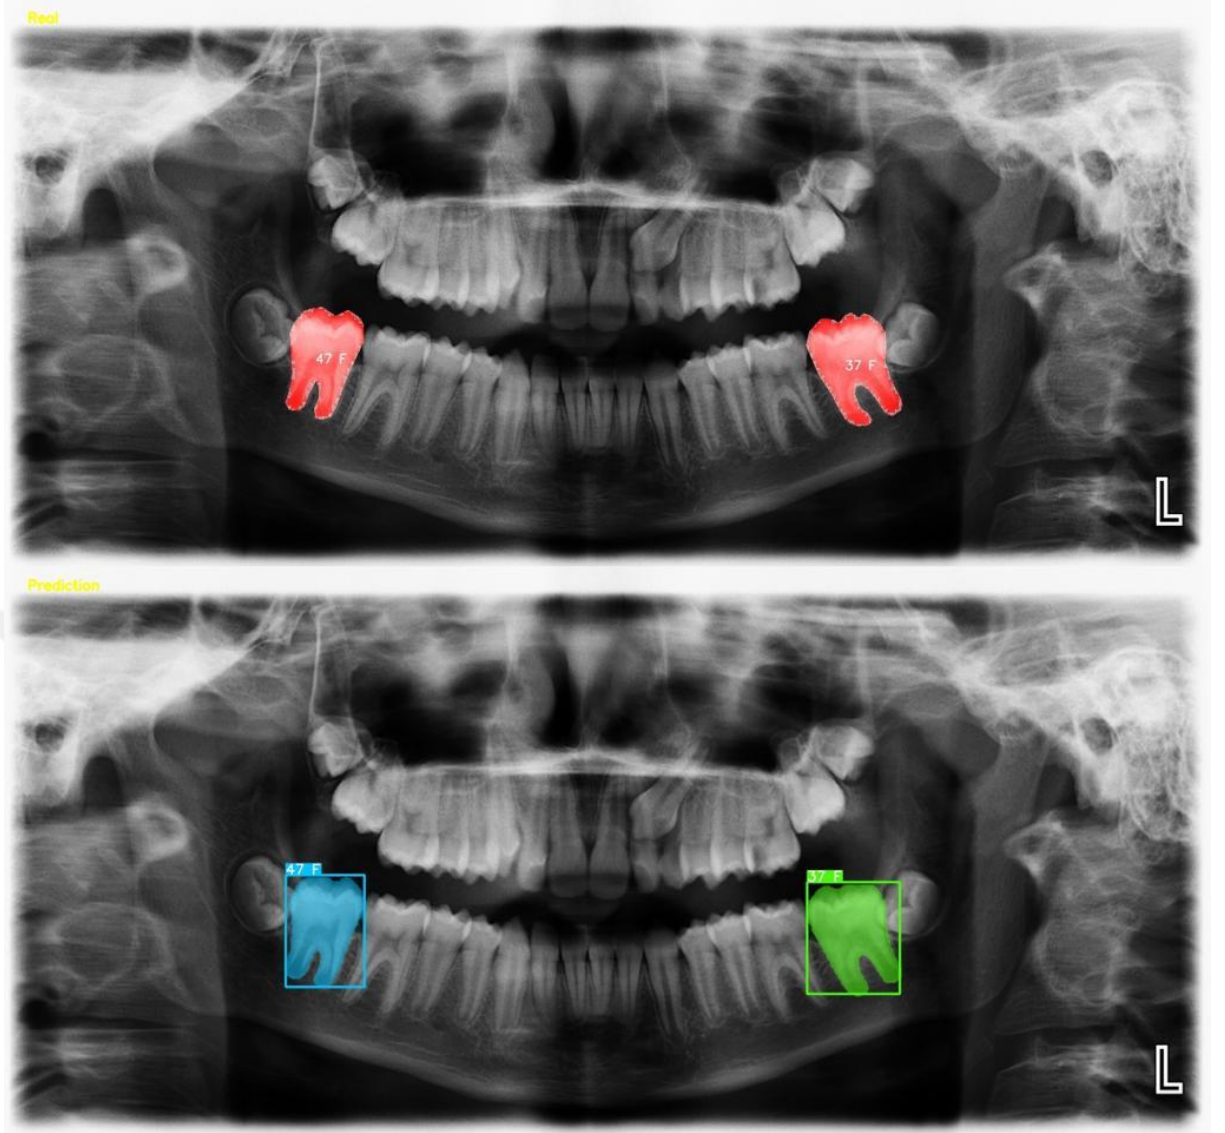
Şekil 4. 4 YOLOv5 modelinin segmentasyon PR eğrisi (kesinlik-duyarlılık eğrisi, precision-recall curve) ve her bir sınıfa ait AUC değerleri.

Tablo 4. 4 Segmentasyon için Kesinlik-duyarlılık eğrisi sonuçları.


Segmentasyon	Kesinlik-Duyarlılık Eğrisi AUC Değeri
37 A	0.913
37 B	0.779
37 C	0.889
37 D	0.973
37 E	0.981
37 F	0.949
37 G	0.923
37 H	0.954
47 A	0.995
47 B	0.978
47 C	0.923
47 D	0.973
47 E	0.984
47 F	0.913
47 G	0.943
47 H	0.991



Şekil 4. 5 Aynı hastaya ait panoramik radyograflardan üstte segmentasyon ile yapılan sınıflama gösterilirken altta ise yapay zekâ modelinin 37 ve 47 numaralı dişler için doğru pozitif tespiti gösterilmiştir.



Şekil 4. 6 Aynı hastaya ait panoramik radyografilerden üstteki segmentasyon ile yapılan sınıflama gösterilirken altta ise yapay zekâ modelinin 37 ve 47 numaralı dişler için doğru pozitif tespiti gösterilmiştir.



Şekil 4. 7 Aynı hastaya ait panoramik radyografilerden üstte detection ile yapılan etiketleme gösterilirken altta ise yapay zekâ modelinin 37 numaralı diş için yanlış pozitif 47 numaralı diş için doğru pozitif tahmini gösterilmiştir.

5. TARTIŞMA

Dişsiz dönemden daimi dişlenme dönemine geçinceye kadar ideal okluzyon ve iyi bir estetiğin oluşabilmesi için birçok fizyolojik mekanizma gerçekleşir. Diş hekimlerinin bu mekanizmaları bilmesi, diş sürmeleri sırasında oluşabilecek sorunların erken teşhisini ve tedavisini sağlar. Böylece ileride yapılacak uzun süreli, maliyetli ve hasta için zor olabilecek tedavi uygulamaları önlenir [224]. Bu nedenle prognozu zayıf birinci büyük azı dişlerinin diş hekimleri tarafından çekimlerinin uygun zamanda yapılmasıyla ark simetrisini sağlamak, okluzal ilişkilerin stabilitesini korumak amacıyla herhangi bir patoloji olmasa dahi gerekirse kompenzasyon ve/veya balans kontrollü çekimlerinin planlanması daha kabul edilebilir bir okluzyon elde edilmesini sağlar.

Birleşik Krallık'taki "Royal College of Surgeons of England" kılavuzunda; üst daimi birinci büyük azı dişlerin kök morfolojisi ve sürme sırasında mezializasyon hareketi sayesinde çok daha rahat bir şekilde istenilen yer kapanmasının sağlanabileceği belirtilmektedir. Bu nedenle alt çenede birinci büyük azıların çekim zamanlaması daha kritik olup çekim için 8-10 yaş arası ile sınırlandırılmıştır. Kırzioğlu ve Ceyhan[225] çalışmalarında; daimi birinci büyük azı dişini erken dönemde çekilen 35 hastayı incelemişler ve daimi birinci büyük azı dişini çekim kararını verirken hastanın yaşı temel alınmadan daimi ikinci büyük azı dişini kök gelişim seviyesinin baz alınmasının daha doğru olacağını rapor etmişlerdir [225]. Bu sebeple çalışmamızı planlarken, daimi birinci büyük azı dişini doğru çekim zamanını belirlemek için daimi ikinci büyük azı dişini gelişim aşamalarını değerlendirdik.

Geçmiş kılavuzlarda "mandibular daimi ikinci büyük azı bifurkasyonun kalsifikasyon başlangıcı" yani "Demirjian E" safhasını, başarılı spontan yer kapanması için belirteç olarak nitelendirilmiştir [98]. Osman Saraç[95]'in yaptığı çalışmada da daimi ikinci moların Demirjian'a göre gelişim evresinin ideal spontan yer kapanması üzerindeki etkisi değerlendirilmiştir. Demirjian D evresinde sadece 5 örneklem olması nedeniyle istatistiksel analize dahil edilememiştir. Üst çenede Demirjian gelişim evresinin bağımsız bir risk faktörü olarak değerlendirildiği univaryans ve multivaryans

analizinde Demirjian E evresi ile F ve G evreleri arasında istatistiksel olarak anlamlı fark bulunmazken, E ve H evreleri arasında anlamlı fark bulunmuştur. Alt çenede ise mevcut kılavuzla uyumlu olarak Demirjian E ile F, G ve H arasında istatistiksel olarak anlamlı fark bulunmuştur [95]. Kötü prognozlu daimi birinci molar dişlerin ideal çekim zamanı özellikle alt çenede önem arz ettiğinden Demirjian metodunu öğrettiğimiz yapay zekâ çalışmamızda literatürle de uyumlu olacak şekilde ideal çekim zamanı için Demirjian E safhasını önerilmiştir.

Literatürde yaş tahmini metotları incelendiğinde; sonuçların toplumdan topluma hatta aynı toplumun farklı bölgelerinde yaşayan çocuklar arasında bile farklılıklar gösterdiği, farklı toplumlarda uygulandığında kronolojik yaş ile diş yaşı arasında önemli farklılıklar görülebildiği, farklılığın giderilmesi için yöntemlerin her topluma özgü olarak modifiye edilmesinin gerekli olduğu sonucuna varılmıştır [95, 226]. Bu metotlardan Demirjian metodunun diğer yöntemler ile karşılaştırıldığı birçok çalışma bulunmaktadır. Olze ve ark.[227] yaptıkları karşılaştırmalı çalışmada Demirjian yöntemini hem gözlemciler arası uyum açısından hem de gelişim evreleri ile kronolojik yaş arasındaki korelasyon açısından en yüksek değerleri gösteren yöntem olarak değerlendirmişlerdir [227]. Dhanjal ve ark.[228] tarafından yapılan bir başka çalışmada ise; Kullman ve ark.[229], Gleiser ve Hunt[44], Harris ve Nortje[230], Gustafson ve ark.[38] ve Demirjian ve ark.[52]'nin geliştirdikleri farklı yöntemler karşılaştırılmış ve sonucunda Demirjian metodunun hem gözlemciler içi hem gözlemciler arası en iyi uyumu gösteren, gerçek yaş ile tahmini yaş arasındaki en yakın sonuçları veren yöntem olarak bildirmişlerdir. Pintana ve ark.[231]'nin Aggregated Channel Features dedektörü ve derin öğrenme ile diş yaşı tahmini için tam otomatik yöntem çalışmasında ise kullanışlı olması nedeniyle Demirjian sınıflamasından faydalanılmıştır. Tunç ve ark. [54]'nin Türkiye'nin kuzeyindeki popülasyonda Demirjian yöntemiyle diş yaşını değerlendirdikleri çalışmalarında; 4-12 yaş aralığında 900 panoramik radyografi değerlendirilmiş ve diş yaşı ile kronolojik yaş arasında güçlü korelasyon bulunmuştur. Çalışmamızda Demirjian metodu; diş gelişim safhalarını belirlemede Dhanjal ve ark.[228], Olze ve ark.[227], Pintana ve ark.[231], Tunç ve ark [54]'nin bulguları referans alınarak ayrıca metodun güncel, pratik, kolay uygulanabilir, ortopantomograma dayalı ve güvenilir bir standardizasyon sağlaması nedeniyle tercih edilmiştir.

Teo ve ark.[80]'ları tarafından 2013 yılında yapılan bir başka çalışmada; üst çenede yaşa bakılmaksızın başarılı kapanma ihtimalinin yüksek olduğu, alt çenede ise Demirjian E döneminde başarılı kapanma gösterenlerin oranının %66, Demirjian F evresinde kapananların %76 olduğu tespit edilmiştir. Teo ve ark.[232] 2016 yılında mezial angulasyona sahip daimi ikinci molar ile beraber üçüncü molar germinin radyografide izlenmesinin başarılı spontan yer kapanmasına etkisini değerlendirmişler ve üçüncü molar germinin bulunmasının Demirjian E evresinden daha önemli bir faktör olduğunu tespit etmişlerdir. Ayrıca 8 yaşında her zaman daimi üçüncü molar germinin panoramik radyografide görülemeyeceğini ve bu yüzden kök gelişiminin yarısına kadar Demirjian F evresine kadar beklenmesi gerektiğini vurgulamışlardır. Bu nedenle mevcut kılavuzun aksine Demirjian E evresinde yapılan çekimlerin başarılı spontan yer kapanması için tek başına belirteç olamayacağı öne sürülmüştür [232]. Teo ve ark.[232]'lerinin çalışmalarının sonuçları bizim referans aldığımız kılavuz sonuçları ile örtüşmemektedir. Yapay zekâ sistemleri ile sadece Demirjian sınıflamasına göre ikinci molarların gelişim aşamalarını değerlendirdiğimiz tez çalışmamızda spontan yer kapanması için ideal çekim zamanını belirlemede etkili olan diğer faktörler değerlendirilmemiştir. Mevcut çalışma öncül bir çalışma olup, tüm parametreler yapay zekâ ile çalışılmamıştır. Gelecekte yapılacak yapay zekâ çalışmalarında ikinci molarların angulasyonu, üçüncü molar germinin varlığı gibi diğer faktörler de dikkate alınarak yapay zekâ sistemleri geliştirilebilir.

İdeal dönemde daimi birinci büyük azı diş çekimlerinin alt ve üst çenede spontan yer kapanması konusunda çeşitli çalışmalar mevcuttur. Bu çalışmalardan Patel ve ark.[83]'lerinin yaptıkları çalışmada üst daimi birinci molarları çekilen hastaların %58,8'i; alt daimi birinci molarları çekilen hastaların %54,9'u ideal dönemde çekilmiştir. Üst çeneye ait tüm daimi ikinci molarların %89,9'u; alt çenede %49'u başarılı spontan yer kapanması göstermiş olup iki çene arasında istatistiksel olarak anlamlı fark bulunmuştur [83]. Osman Saraç [95] 'ın Malatya ili ve çevresini içeren başarılı ve başarısız spontan yer kapanmasının çenelere göre dağılımını değerlendirdiği retrospektif tez çalışmasında; farklı nedenlerle çekilen daimi birinci molarların 145 tanesi üst çenede yer alırken; 270 tanesi alt çenede yer almaktadır. Üst çeneye göre alt çenelerde başarısızlık riski 8,724 kat daha fazla bulunmuştur [95]. Literatüre paralel olarak üst dişlerin görüntülenmesi zor ve spontan yer kapanma başarısı yüksek iken, alt çenede yaşa bağlı spontan yer kapanma başarısının daha

düşük olması sebebiyle çalışmamızda yalnızca alt daimi ikinci molarlar değerlendirilmiştir.

Diş hekimliği alanında, iki boyutlu görüntülerden bitewing, periapikal gibi intraoral görüntülemeler, lateral sefalometrik, antero-posterior sefalometrik ve panoramik radyografiler gibi ekstraoral görüntülemeler ve üç boyutlu görüntülerden Konik Işınlı Bilgisayarlı Tomografi (KIBT) görüntüleri gibi farklı türdeki görüntüleme yöntemleri kullanılarak yapılmış birçok yapay zeka çalışması mevcuttur. Yasa ve ark.[180] diş tespit ve segmentasyonu çalışmasında, Fadel ve ark.[233] taşkın restorasyonların tespitinde, Cantu ve ark.[185] çürük tespitinde, Karaataş ve ark.[234] dental restorasyon sınıflamasında bite-wing radyografi görüntülerinden yararlanırken; Chen ve ark.[179] diş tespit ve segmentasyonunda, Lee ve ark.[183] çürük tespitinde, Fadel ve ark.[233] taşkın restorasyonların tespitinde, yine Lee ve ark.[193] periodontal hastalıkla ilişkili durumu kritik dişlerin belirlenmesinde, Kyventidis ve ark.[235] anatomik landmark tespitinde, Karaataş ve ark.[234] dental restorasyon sınıflamasında, Cha ve ark.[236] implant çevresi kemik kaybı ölçümü çalışmalarında periapikal radyograflardan faydalanmışlardır. Bunlara ilave olarak Kılıç ve ark.[237] diş tespit ve segmentasyonunda, Hiraiwa ve ark.[187] molar dişlerde ekstra kök varlığı tespitinde, Fukuda ve ark.[238] vertikal kök kırıkları tespitinde, Ekert ve ark.[191] apikal lezyon tespitinde, Kuwada ve ark. [202] gömülü süpernümerer diş varlığı tespitinde, Patil ve ark.[239] adli diş hekimliğinde, Krois ve ark.[195] periodontal kemik kaybı tespitinde, Sukegawa ve ark.[240] implant marka ve tedavi aşaması tespitinde, Yang ve ark.[205] odontojenik kist ve tümör tespitinde, Son ve ark.[241] mandibula fraktür tespitinde, Yoo ve ark. [4] üçüncü molar dişlerin çekim zorluğunun değerlendirilmesinde panoramik radyografiler kullanırken; Chen ve ark.[242] diş tespit ve segmentasyonunda, Orhan ve ark.[5] gömülü mandibular üçüncü molarların değerlendirilmesinde, Orhan ve ark.[192]periapikal patolojilerin tespitinde, Choi ve ark.[243] ortognatik cerrahide, Bayrakdar ve ark.[244] implantolojide, Sin ve ark. [245] farengeal hava yolu tespit ve segmentasyonunda KIBT görüntülerinden faydalanmışlardır. Panoramik radyografilerin rutinde kullanımının yüksek olması, standardizasyon sağlaması ve Demirjian metodunun bu radyografiye dayanması sebebiyle çalışmamızda panoramik radyografiden faydalanılmıştır.

Yapay zekâ sistemlerine radyografilerdeki anatomi ve patolojilerin öğretilmesi hekimler için önemli bir karar destek mekanizması görevi görür [246-249]. Bu anlamda dişlerin gelişim aşamaları ve/veya yaş tahmini ile ilgili de çeşitli yapay zekâ çalışmaları mevcuttur.

Banar ve ark. derin öğrenmeye dayalı yapay zekâ modeli ile yaptıkları çalışmalarında, yaş tahmini yapabilmek için 400 panoramik radyografi üzerinden sol mandibular üçüncü molar dişlerin gelişim aşamalarını belirlemede modifiye Demirjian tekniğini kullanmışlardır. Bu tekniğe göre dişlerin gelişim aşamalarını 10 gruba ayırmış ve her grup için 20 panoramik radyografi ile çalışmışlardır. Etiketleme yöntemi olarak detection yöntemi, derin öğrenme mimarilerinden de Alex Net mimarisi kullanılmıştır [250]. Pintana ve ark.[231] tarafından yapılan diğer bir benzer çalışmada ise yine Demirjian sınıflaması kullanılmış ancak sınıflandırmaya ait beş evre (D-H) çalışmaya dahil edilmiştir. Modeli eğitmek için 800, test etmek için 200 panoramik radyografi detection yöntemiyle mandibular üçüncü molar diş üzerinde etiketlenmiştir. Önceden eğitilmiş ağ olan ResNet50 mimarisi kullanılmıştır. Aljameel ve ark.[251]'nin dental yaşı tahmin etmek için panoramik radyografi görüntüleri kullanılarak derin öğrenmeye dayalı bir regresyon modeli geliştirdikleri çalışmada; veri seti 529 panoramik radyografi üzerinden sol yedi mandibular diş kullanılarak eğitilmiştir. Görüntüler yalnızca öğrenme süreci için gerekli dişleri içerecek şekilde kırılmıştır [251]. Modeli uygulamak için Xception, VGG16, DenseNet121 ve ResNet50 olmak üzere farklı derin öğrenme mimarileri uygulandığı çalışmada, Xception modelinin 6-11 yaş grubu için en iyi performansı gösterdiği rapor edilmiştir [251]. Kılıç ve ark.[237]'nin 402 adet panoramik radyografi görüntüleri üzerinde süt dişi tespit ve numaralandırma için yaptıkları derin öğrenme temelli çalışmada; Faster R-CNN (Region-Based Convolutional Neural Network) Inception v2 (COCO) modeli kullanılmıştır. Tuzoff ve ark.[175]'nin 1352 adet panoramik radyografi üzerinde diş tespit ve numaralandırma yaptıkları benzer çalışmada; Faster R-CNN mimarisi kullanılmış ve oldukça başarılı sonuçlar bulunmuştur. Lee ve ark.[177]'nin 50 panoramik radyografi üzerinden diş segmentasyonu yaptıkları çalışmada; Maske R-CNN mimarisi kullanılmıştır. Shaheen ve ark.[252] çalışmalarında 186 görüntüden oluşan veri seti ile KIBT görüntüleri üzerinden otomatik diş segmentasyonu ve sınıflandırması için 3D U-Net mimarisini kullanmışlardır. Widiyasri ve ark.[253]'nin dental implant planlamasında mandibular kanalın tam konumunun, alveol kemik

yüksekliğinin ve genişliğinin belirlenmesi için KIBT görüntülerine dayalı olarak yaptıkları çalışmada; detection yöntemi ile YOLOv4'ün verimli bir versiyonu olan Dental-YOLO modeli kullanılmış ve radyologlar tarafından yapılan manuel ölçümlerle arasında fark olmadığı belirlenmiştir. Ayrıca Çelik[254]'in farklı mimariler kullanarak panoramik radyograflar üzerinde gömülü üçüncü molar dişleri tespit etmedeki performanslarını kıyasladıkları çalışmada; iki aşamalı bir teknik olarak, ResNet50, AlexNet ve VGG16 ile Faster RCNN ve tek aşamalı bir teknik olan YOLOv3 kullanılmış ve YOLOv3'ün panoramik radyograflarda gömülü mandibular üçüncü molar diş tespiti için mükemmel performansa sahip olduğu görülmüştür. Çalışmamızda; zaman içerisinde yapay zekâ mimarilerinin gelişmesi ile güncel ve başarılı bir mimari olan YOLOv5 mimarisi küçük boyutu, hızlı hesaplama kapasitesi ve basit yapısı nedeniyle kullanılmıştır.

Pintana ve ark.[231] tarafından yapılan bir çalışmada; Demirjian sınıflaması kullanılmış sınıflandırmaya ait beş evre (D-H) çalışmaya dahil edilmiştir. Modeli eğitmek için 800, test etmek için 200 radyografi detection yöntemiyle mandibular üçüncü molar diş üzerinde etiketlenmiştir. Önceden eğitilmiş ağ olan ResNet50 mimarisi temel alınarak transfer öğrenme tekniği kullanılarak eğitilmiştir. Sınıflandırma sonuçları, doğruluk yüzdesinin ortalama olarak %83.25 olduğu 67.50 ile % 97.50 arasında değiştiğini göstermiştir. Sınıflandırma sonuçlarına göre, erken aşamaların (D ve E) kökleri diğer aşamalardan önemli ölçüde farklı olduğundan sınıflandırılmaları kolayken, sonraki aşamaların (F'den H'ye) kök yapıları benzer olduğundan ayırt etmek daha zor olmuştur. Buna bağlı olarak erken aşamaların doğruluğu daha yüksek bulunmuştur. Çalışmalarının sonucunda; modellerin tahminlerde yaptığı hataların çoğunlukla yakın sınıflar arasında olduğunu belirtmişlerdir [231]. Bizim tez çalışmamızda da sınıflama için kullandığımız modelin tahminlemede yaptığı hatalar yine yakın sınıflar arasındadır ve Pintana ve ark.[231] tarafından yapılan çalışmanın sonuçları ile örtüşmektedir. Bizim sınıflandırma sonuçlarımız tüm sınıflar için detection yönteminde 0,938 segmentasyon yönteminde ise 0,941 bulunmuştur. Bizim çalışmamızda her sınıf için örneklem sayısının daha az olmasına rağmen sonuçların daha başarılı bulunması güncel mimari kullanımı, farklı epoch değerlerinde çalışılması ve yapay zekâ sistemlerinin gün geçtikçe gelişmesi kaynaklı olabileceği düşünülmektedir.

Mohammad ve ark. [255]'nin retrospektif olarak daimi mandibular birinci ve ikinci premolar dişlerin gelişim seviyelerini Demirjian sınıflamasını kullanarak değerlendirdikleri çalışmalarında; 5-14 yaşları arasında 240 panoramik radyograf veri seti olarak elde edilmiştir. Keras tabanlı bir derin öğrenme konvolüsyonel sinir ağı (DCNN) modeli kullanılmış ve segmentasyon yöntemiyle etiketlemeler yapılmıştır. Sonuçların doğruluğu eğitim, doğrulama ve test veri setinde sırasıyla %97.74, %96.63 ve %78.13 olarak bulunmuştur. Önerilen DCNN modeli, C, G ve H aşamalarındaki test verilerinin %90'undan fazlasının doğru şekilde belirlenmesi nedeniyle umut verici görünmektedir. D, E ve F aşamalarındaki daha düşük doğruluk, aşamalar arasındaki dişlenmenin morfolojik yapısının önemli farklılıklarından kaynaklanıyor olabilir [255]. Çalışmamızda ise detection ve segmentasyon yöntemleri ile etiketlemeler yapılmış ve her iki yöntemde de doğruluk değeri 0,909 olarak bulunmuştur. Sonuçlar arasındaki farklılığın kullanılan yapay zeka mimarisi, veri seti sayıları, değerlendirilen dişlerin farklı anatomik yapıları kaynaklı olabileceği düşünülmektedir.

Kılıc ve ark. [237]'nin çocuk hastaların panoramik radyografi görüntüleri üzerinde süt dişi tespit ve numaralandırması için yaptıkları derin öğrenme temelli çalışmada; 402 adet panoramik radyografi üzerinden Faster R-CNN (Region-Based Convolutional Neural Network) Inception v2 (COCO) modelini kullanan yapay zekâ algoritması geliştirmişlerdir. Modelin duyarlılık, kesinlik ve F1 skoru değerlerinin sırasıyla 0.9804, 0.9571 ve 0.9686 olarak tespit edildiğini ve sistemin yüksek oranda başarı gösterdiğini bildirmişlerdir. Tuzoff ve ark.[175]'nin 1352 adet panoramik radyografi üzerinde diş tespit ve numaralandırma yaptıkları çalışmada; Faster R-CNN mimarisi kullanılmış olup, dişleri tespit etmedeki duyarlılık, kesinlik ve F1 skoru sırasıyla 0.9941, 0.9945, 0.9942 olarak bulunmuştur. Bilgir ve ark.[181]'nin 2482 adet panoramik radyografi üzerinde FDI sistemine göre dişlerin tespiti ve numaralandırmasını gerçekleştirdikleri çalışmada; Faster R-CNN Inception v2 mimarisi kullanılmış ve 200.00 epoch eğitilen modelde elde edilen duyarlılık, kesinlik ve F1 skorları sırasıyla 0.9559, 0.9652 ve 0.9606'dır. Bizim çalışmamızda ise diş gelişim aşamalarını belirlemek için model geliştirilirken 500 epoch ile eğitilmiş YOLOv5 mimarisi kullanılmış olup, 1106 panoramik görüntü üzerinden detection yöntemi ile 2100 adet etiketlenmiş görüntü kullanılmıştır. Modelimizin; duyarlılık, kesinlik, F1 skoru değerleri sırasıyla; 0.990, 0.917, 0.952 şeklindedir. Bu tez çalışması diş numaralandırma ve tespit çalışmalarından daha komplike ve sınıflandırmaya

dayanan bir yapay zeka çalışması olup; sonucunda oldukça başarılı oranlar elde edilmiştir.

Lee ve ark.[177]'nin 50 panoramik radyografi üzerinden diş segmentasyonu yaptıkları çalışmada; Maske R-CNN mimarisi kullanılmış ve veri artırma yapılarak 846 orijinal veri noktasından 1024 eğitim örneği elde edilmiştir. Yöntemde duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.893, 0.858 ve 0.875 olarak bulunmuştur. Silva ve ark.[256] tarafından Maske R-CNN mimarisinin ön uygulamasını tanıttıkları benzer bir çalışmada ise 6 panoramik radyografi üzerinden diş segmentasyonu yapılmış ve duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0.837, 0.672 ve 0.794 olarak bulunmuştur. Shaheen ve ark.[252] çalışmalarında 186 görüntüden oluşan veri seti ile KIBT görüntüleri üzerinden otomatik diş segmentasyonu ve sınıflandırması için bir derin öğrenme yaklaşımı geliştirmişlerdir. Dişleri segmentlere ayırmak ve sınıflandırmak için bir yapay zekâ çerçevesi 3D U-Net kullanmışlardır. Diş segmentasyonunda duyarlılık, kesinlik ve F1 skoru değerlerini sırasıyla yaklaşık olarak 0.83, 0.98 ve 0.89 olarak ölçmüşlerdir. YOLOv5 mimarisi ile eğitilmiş 1106 panoramik radyografi ile değerlendirdiğimiz çalışmamızda ise segmentasyon yöntemi ile yapılan etiketlemeler sonucu 0,985 duyarlılık, 0,921 kesinlik, 0,952 F1 skoru değerleri elde edilmiştir. Mevcut çalışmamız ile diğer çalışmalar; duyarlılık, kesinlik ve F1 skoru açısından kıyaslandığında en başarılı sonuçların çalışmamızda elde edildiği görülmektedir. Bu farklılığın nedeni, veri seti sayılarının farklı olması, farklı mimarilerin kullanılması, YOLOv5 mimarisinin segmentasyon yöntemindeki başarısı, farklı görüntüleme yöntemlerinden elde edilen veri setlerinin kullanılmasından kaynaklandığı düşünülmektedir.

Widiasri ve ark.[253]'nin mandibular posterior dental implant planlamasında mandibular kanalın tam konumunun, alveol kemik yüksekliğinin ve genişliğinin belirlenmesi için KIBT görüntülerine dayalı otomatik ve eşzamanlı bir tespit sistemi önerdikleri çalışmada; implant alanındaki mevcut kemik yüksekliği ve genişliği, detection yöntemi kullanılarak tahmin edilmiştir. Dental-YOLO modeli kullanılarak alveol kemik ve mandibular kanal tespit performanslarını değerlendirmede mAP değeri 0,9946 bulunmuştur. Çalışmanın sonucunda Dental-YOLO kullanılarak yapılan ölçümler ile radyologlar tarafından yapılan manuel ölçümler arasında fark olmadığı ve Dental-YOLO tespit sistemi ile hızlı ve başarılı sonuçlar elde edildiği belirlenmiştir.

Çelik[254]'in farklı mimariler kullanarak üçüncü molar gömülü dişlerin tespiti için ESA'ya dayalı bilgisayar destekli bir tespit sistemi geliştirmek ve önerilen çözümlerin panoramik radyograflar üzerindeki potansiyel kullanılabilirliğini ve doğruluğunu değerlendirmek üzere yaptığı çalışmada; toplam 440 panoramik radyografi kullanılmıştır. İki aşamalı bir teknik olarak, ResNet50, AlexNet ve VGG16 ile Faster RCNN ve tek aşamalı bir teknik olan YOLOv3 kullanılmıştır. mAP@0.5 değerleri incelendiğinde ResNet50 bazlı Faster-RCNN ile 0.91, VGG16 ve AlexNet sırasıyla 0.87, 0.86 olarak bulunmuştur. YOLOv3, 0,96'lık değer ile en yüksek tespit etkinliğini sağlamıştır. YOLOv3'ün panoramik radyograflarda gömülü mandibular üçüncü molar diş tespiti için mükemmel performansa sahip olduğu görülmüştür. Farklı mimarilerden elde edilen bulgular göz önüne alındığında, son teknoloji derin öğrenme modellerine dayanan teşhis araçlarının klinik karar verme için güvenilir ve sağlam olduğunu rapor etmişlerdir. Çalışmamızda ise; detection yöntemi ile etiketlemeler sonucu mAP@0.5 değeri 0.93813 iken, segmentasyon yönteminde ise mAP@0.5 değeri 0.94136 bulunmuştur. Çalışmanın sonuçları farklı mimariler bazında değerlendirildiğinde YOLOv5'in iki aşamalı tekniklerden daha başarılı sonuçlar elde ettiği görülmüştür. Bu durumun farklı veri seti sayıları, YOLOv5'in nesne tespit etmedeki başarısı kaynaklı olduğu düşünülmüştür. Çelik [254]'in tek aşamalı bir teknik olan YOLOv3 mimarisi ve daha az veri seti sayıları kullanılarak elde edilen sonuçların; daha yüksek veri sayıları ve YOLOv5 mimarisi kullanarak elde ettiğimiz sonuçlardan daha başarılı olmasının nedenleri ise Çelik[254]'in çalışmasının tek parametre içeren temel bir çalışma olması, çalışmamızın ise çok sayıda grup içeren kompleks bir çalışma olması ile açıklanabilir.

Çalışmamızın başlıca limitasyonları şu şekilde özetlenebilir:

Çekim endikasyonu olan daimi birinci molar dişlerin ideal çekim zamanının panoramik radyografiler üzerinden belirlenmesinde etkili çeşitli faktörler vardır. Bunlar; süt ikinci moların furkasyonu ile ikinci premoların ilişkisi, daimi ikinci moların angulasyonu, üçüncü molar germinin izlenmesi, çekimin yapılacağı çene ve daimi ikinci molar dişin gelişim evresidir. Yapay zekâ temelli çalışmamızda yalnızca daimi ikinci molar dişin gelişim evresi dikkate alınmıştır. Gelecekte daimi birinci molar dişin ideal çekim zamanını belirlemede etkili olabilecek diğer faktörlerin de değerlendirildiği yapay zekâ çalışmaları yapılabilir.

Çalışmamıza ait veri seti Bezmialem Vakıf Üniversitesi Diş hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi arşiv kayıtlarından elde edilmiştir. Veri setini oluşturan bütün görüntüler aynı panoramik cihazında, aynı parametrelerle çekilen görüntülerden oluşmaktadır. Farklı cihazlar ve farklı çekim parametreleri uygulanarak elde edilecek görüntülerle yapılacak olan çalışmalar ile daha etkin yapay zekâya dayalı çalışma sonuçları elde edilebilir.

Çalışmamıza artefaktlı görüntüler, 36, 37, 46, 47 numaralı diş eksikliği olan hastalar ve 37 ve/veya 47 numaralı dişlerinde çürük, periapikal lezyon veya patolojiye sahip hastalar veri setine dahil edilmemiştir. İlerleyen dönemlerde yapılacak olan çalışmalarda çalışmaya dâhil etme kriterleri genişletilerek klinik uygulama açısından daha yararlı yapay zekâ algoritmaları elde edilmesi sağlanabilir.

6. SONUÇLAR

Daimi birinci büyük azı dişlerin çekimi tüm oklüzyonu ve diş arkını etkileyerek çeşitli sonuçlar doğurabileceği için çekimi planlanırken dikkatli bir değerlendirme yapılmalıdır. Böylece oluşabilecek olumsuzlukların önüne geçilerek oklüzyonun düzgün gelişimi ve estetik sağlanır. Bu çalışmada; yapay zekâ algoritmaları tarafından; daimi ikinci büyük azı dişlerin gelişim aşaması değerlendirilmiş, prognozu kötü olan daimi birinci büyük azı dişlerin çekim sonrası ideal spontan yer kapanmasında muhtemel komplikasyonların en aza indirgenmesi ve ideal çekim zamanının belirlenmesinde hekimlere yardımcı olabilecek bir karar destek mekanizmasının gelişimine katkı sağlanmıştır. Demirjian metoduna göre panoramik radyografi üzerinden YOLOv5 mimarisi kullanılarak daimi ikinci molarların gelişim aşaması belirlenmiş ve başarılı sonuçlar elde edilmiştir.

Çalışmamızda; Demirjian metodunun sekiz safhası panoramik radyografiler üzerinden detection ve segmentasyon yöntemleri ile etiketlenmiştir. Detection yönteminde doğruluk, duyarlılık, kesinlik, F1 skoru ve mAP@0.5 değeri sırasıyla 0.909, 0.990, 0.917, 0.952 ve 0.938 olarak; segmentasyon yönteminde ise aynı değerler sırasıyla 0.909, 0.985, 0.921, 0.952 ve 0.941 olarak bulunmuştur. Segmentasyon yöntemi ile elde edilen sonuçlar küçük bir farkla detection yöntemi ile elde edilen sonuçlardan daha başarılı bulunmuştur.

Sonuçlar oldukça umut verici olmakla birlikte geliştirmeler yapılabilir. Her grup için örneklem sayısının artırılması, veri artırma tekniklerinin kullanılması faydalı olacaktır. Böylece hem hesaplama karmaşıklığı azaltılacak hem de öğrenme süreci iyileştirilecektir.

Çalışmamızda son derece verimli, nesne algılamada oldukça başarılı olan YOLOv5 mimarisi kullanılmıştır ancak gün geçtikçe yapay zekâ sistemleri gelişmektedir. Gelecekte yapılacak olan çalışmalarda daha iyi sonuçlar elde etmek, başarı oranlarını arttırmak ve geliştirilen modelin rutin klinik kullanıma girmesini sağlamak için daha güncel ve çeşitli özelliklere sahip yapay zekâ mimarileri kullanılabilir. Böylece aynı veriler üzerinden farklı mimarilerin başarısı karşılaştırılabilir ve zaman içerisinde iyileştirilebilir.

Yapay zekâ destekli sistemler, klinik rutinde hekimlere zaman kazandıracak ve teşhis, tanı ve tedavi planlamasında doğru, hızlı ve güvenilir sonuçlar verecektir.



7. KAYNAKÇA

1. Şenyurt, F. and E.H. Bodrumlu, *Çocuklarda Daimi Birinci Büyük Azı Diş Çekim Nedenleri Ve Etkileri*. Selcuk Dental Journal, 2019. **6**(1): p. 98-104.
2. Kiraz, M., B.N. Yüksel, and S. Şaziye, *Daimi birinci büyük azı dişlerinin kontrollü çekimleri: derleme*. Acta Odontologica Turcica, 2018. **35**(2): p. 56-61.
3. Santos, K.K., et al., *Prevalence of mandibular third molars according to the Pell & Gregory and Winter classifications*. Journal of maxillofacial and oral surgery, 2022: p. 1-7.
4. Yoo, J.H., et al., *Deep learning based prediction of extraction difficulty for mandibular third molars*. Sci Rep, 2021. **11**(1): p. 1954.
5. Orhan, K., et al., *Evaluation of artificial intelligence for detecting impacted third molars on cone-beam computed tomography scans*. J Stomatol Oral Maxillofac Surg, 2021. **122**(4): p. 333-337.
6. ÖZBEK, E., S. GEDİKLİ, and U.D. tuba DEMİRCİ, *Dişin embriyolojik gelişimini düzenleyen sinyal molekülleri*. Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi, 2012. **2012**(2): p. 217-223.
7. BARLAK, P. and F. SEYMEN, *DİŞ GELİŞİMİNE MOLEKÜLER, GENETİK VE HİSTOLOJİK YAKLAŞIM*. Journal of Istanbul University Faculty of Dentistry, 2013. **47**(2): p. 64-72.
8. BERKE, N. and N. Keklikoğlu, *NÖRAL KREST KÖKENLİ HÜCRELERİN AĞIZ VE ÇENE-YÜZ OLUŞUMUNA KATKILARI VE NEDEN OLDUKLARI ANOMALİLER*. Journal of Istanbul University Faculty of Dentistry, 2010. **44**(1): p. 39-43.
9. Emek, T., *Spor yapan ve yapmayan bireylerin diş gelişimi ve ağız sağlığı durumunun incelenmesi*. 2019.
10. BAHAR, L., *DİŞİN EMBRİYOLOJİK GELİŞİMİ*. SAĞLIK & BİLİM 2023: Genel Embriyoloji-I, 2023: p. 137.
11. Nebahat, İ. and G.S. SARIBAŞ, *DİŞ GELİŞİMİ*. SAĞLIK & BİLİM 2022: Genel Embriyoloji-II, 2023: p. 65.
12. SİRKECİ, S., *Üçüncü Azı Diş Gelişiminin Kronolojik Yaşla İlişkisinin Demirjian Yöntemi ile Değerlendirilmesi*. 2018.
13. Thesleff, I. and P. Sharpe, *Signalling networks regulating dental development*. Mechanisms of development, 1997. **67**(2): p. 111-123.
14. ÖZER, S.A., *YENİDOĞAN SIÇANLARA UYGULANAN PROPOFOLÜN DİŞ GELİŞİMİ ÜZERİNE ETKİSİNİN İNCELENMESİ*. 2017.
15. Jussila, M., E. Juuri, and I. Thesleff, *Tooth morphogenesis and renewal*. Stem cells in craniofacial development and regeneration, 2013: p. 109-134.
16. Tural, M., *Çocuklarda farklı diş yaşı tespit yöntemlerinin güvenilirliğinin değerlendirilmesi*.
17. Avery, J. and D. Chiego, *Eruption and shedding of teeth*. Essentials of oral histology and embryology: A clinical approach, 1992: p. 72-83.
18. Zohrabian, V.M., C.S. Poon, and J.J. Abrahams. *Embryology and Anatomy of the Jaw and Dentition*. in *Seminars in Ultrasound, CT and MRI*. 2015. Elsevier.
19. Proffit, W.R., et al., *Contemporary Orthodontics*. St. Louis. Mo: Mosby, 2000.
20. Ülgen, M., *Ortodonti: anomaliler, sefalometri, etoloji, büyüme ve gelişim, tanı*. 2000: Yeditepe Üniversitesi.
21. Ülgen, M., *Ortodontik tedavi prensipleri*. 1993.
22. Proffit, W.R., et al., *Contemporary Orthodontics, 6e: South Asia Edition-E-Book*. 2019: Elsevier India.
23. Demirkıran, D.S., et al., *Yaş tespitinde kullanılan yöntemler*. Dicle Medical Journal/Dicle Tıp Dergisi, 2014. **41**(1).
24. ISIR, A.B., *Adli Hekimlikte Yaş Tayini*. Editörler: Prof. Dr. Sermet KOÇ Yrd. Doç. Dr. Muhammet CAN, 2009. **222**.
25. Akay, G., N. Atak, and K. Güngör, *Adli dişhekimliğinde dişler kullanılarak yapılan yaş tayini yöntemleri*. Ege Üniversitesi Diş Hekimliği Fakültesi Dergisi, 2018. **39**(2): p. 73-82.
26. Ünver, T., *El-Bilek Kemikleri, Servikal Vertebra Ve Dişlerin Gelişimdönemlerine Göre Kronolojik Yaş Evrelerinin El-Bilek Grafileri Ve Dental Volumetrik Tomografi Ile Karşılaştırmalı Olarak Değerlendirilmesi*. 2013, Marmara Üniversitesi (Turkey).

27. ÇEKER, D., *Adli antropolojide yaş tahmini metodları*. Antropoloji, 2018(35): p. 35-54.
28. Doğan, F.B. and F. Akgünlü, *Kronolojik, dental ve iskeletsel yaş arasındaki korelasyonun değerlendirilmesi*. Selcuk Dental Journal, 2019. **6**(4): p. 420-424.
29. Yadav, V., A. Loomba, and R. Autar, *A comparative evaluation of dental calcification stages and skeletal maturity indicators in North-Indian children*. National Journal of Maxillofacial Surgery, 2017. **8**(1): p. 26.
30. Cardoso, H.F.V., *Accuracy of Developing Tooth Length as an Estimate of Age in Human Skeletal Remains: The Permanent Dentition*. The American Journal of Forensic Medicine and Pathology, 2009. **30**(2): p. 127-133.
31. GÜMRÜ, B., E. İDMAN, and Ş.E. YALÇINKAYA, *Çocuk ve yetişkinlerde radyolojik dental yaş tayini yöntemleri ve kullanılan radyolojik teknikler*. Sağlık Bilimlerinde, 2022.
32. Boyacıoğlu, H. and N. Avcu, *Dental Radyograflarda Yetişkinler İçin Yaş Tayini Yöntemleri*. 2020.
33. Wochna, K., et al., *Aspartic acid racemization of root dentin used for dental age estimation in a Polish population sample*. Forensic Science, Medicine and Pathology, 2018. **14**(3): p. 285-294.
34. Swetha, G., et al., *Quantitative analysis of dental age estimation by incremental line of cementum*. Journal of oral and maxillofacial pathology: JOMFP, 2018. **22**(1): p. 138.
35. Kurniawan, A., et al., *The Applicable Dental Age Estimation Methods for Children and Adolescents in Indonesia*. International Journal of Dentistry, 2022. **2022**: p. 6761476.
36. PRIYADARSHINI, C., M.P. Puranik, and S. Uma, *DENTAL AGE ESTIMATION METHODS-A REVIEW*. 2015: LAP Lambert Academic Publ.
37. Haavikko, K., *Tooth formation age estimated on a few selected teeth*. A simple method for clinical use. Procc Finn Dent Soc, 1974. **70**(1): p. 15-9.
38. Gustafson, G., *Age determinations on teeth*. The Journal of the American Dental Association, 1950. **41**(1): p. 45-54.
39. Hekimliği, H.A.A.D., *Erzurum*. Eser Ofset, 2006: p. 12-68.
40. Ritz, S., H. Schütz, and C. Peper, *Postmortem estimation of age at death based on aspartic acid racemization in dentin: its applicability for root dentin*. International journal of legal medicine, 1993. **105**: p. 289-293.
41. Miles, A., *Dentition in the estimation of age*. Journal of Dental Research, 1963. **42**(1): p. 255-263.
42. Logan, W.H. and R. Kronfeld, *Development of the human jaws and surrounding structures from birth to the age of fifteen years*. The Journal of the American Dental Association (1922), 1933. **20**(3): p. 379-428.
43. Massler, M. and I. Schour, *Studies in tooth development: theories of eruption*. American Journal of Orthodontics and Oral Surgery, 1941. **27**(10): p. 552-576.
44. Gleiser, I. and E. Hunt, *The estimation of age and sex of preadolescent children from bones and teeth*. Am J Phys Anthr, 1955. **13**: p. 479-488.
45. Gleiser, I. and E.E. Hunt Jr, *The permanent mandibular first molar: its calcification, eruption and decay*. American journal of physical anthropology, 1955. **13**(2): p. 253-283.
46. Nolla, C.M., *The development of permanent teeth*. 1952, University of Michigan Ann Arbor.
47. Moorrees, C.F., E.A. Fanning, and E.E. Hunt Jr, *Age variation of formation stages for ten permanent teeth*. Journal of dental research, 1963. **42**(6): p. 1490-1502.
48. Anderson, D., G. Thompson, and F. Popovich, *Age of attainment of mineralization stages of the permanent dentition*. Journal of Forensic Sciences, 1976. **21**(1): p. 191-200.
49. Nyström, M., et al., *Dental maturity in Finnish children, estimated from the development of seven permanent mandibular teeth*. Acta Odontologica Scandinavica, 1986. **44**(4): p. 193-198.
50. Singla, Y., et al., *Age estimation by forensic Odontology*. International Journal of Current Research in Life Sciences, 2018. **7**(05): p. 2097-2100.
51. Panchbhai, A., *Dental radiographic indicators, a key to age estimation*. Dentomaxillofacial Radiology, 2011. **40**(4): p. 199-212.
52. Demirjian, A., H. Goldstein, and J.M. Tanner, *A new system of dental age assessment*. Human biology, 1973: p. 211-227.
53. Demirjian, A. and H. Goldstein, *New systems for dental maturity based on seven and four teeth*. Annals of human biology, 1976. **3**(5): p. 411-421.
54. Tunc, E.S. and A.E. Koyuturk, *Dental age assessment using Demirjian's method on northern Turkish children*. Forensic science international, 2008. **175**(1): p. 23-26.

55. Zouashkiani, T. and T. Mirzakhani, *Parental knowledge about presence of the first permanent molar and its effect on health of the this tooth in 7-8 years-old children (2006)*. Journal of Mashhad Dental School, 2006. **30**(3, 4): p. 225-232.
56. KILINÇ, G., et al., *12-18 YAŞ GRUBU ÇOCUKLARDA DAIMİ BİRİNCİ BÜYÜK AZI DIŞLERİN DURUM DEĞERLENDİRİLMESİ: RETROSPEKTİF RADYOGRAFİK ÇALIŞMA*. Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi, 2016. **26**(1).
57. Avery, J.K. and D.J. Chiego, *Essentials of oral histology and embryology: a clinical approach*. 2007: Reed Elsevier.
58. Duman, S. and G. Duruk, *6-12 Yaş Grubu Çocuklarda Daimi Birinci Büyük Azı Dişlerin Önemi Ve Değerlendirilmesi–Derleme*. Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi, 2018. **28**(4): p. 610-624.
59. Douglass, C., *The Importance of Parental Knowledge in Controlling Early Childhood Caries*. A Summary Journal of Advances in Dentistry and Oral Health Care, 2005. **15**: p. 1-10.
60. Abernathy, J.R., et al., *Application of life table methodology in determining dental caries rates*. Community dentistry and oral epidemiology, 1986. **14**(5): p. 261-264.
61. MADEN, D.E.A. and C. ALTUN, *Çocuk dişhekimliğinde kötü prognozlu daimi birinci molarların çekim endikasyonları ve klinik değerlendirmeleri*. Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi, 2013. **23**(3): p. 408-413.
62. Cheng, R.-B., et al., *Analysis of the first permanent molar caries epidemiological investigation in area of northeast China*. Hua xi kou qiang yi xue za zhi= Huaxi kouqiang yixue zazhi= West China journal of stomatology, 2008. **26**(1): p. 73-76.
63. Karabekiroğlu, S. and N. Ünlü, *Yüksek Çürük Riskli Genç Yetişkinlerde Diş Çürüğüne Ait Temel Parametrelerin Değerlendirilmesi*. 2014.
64. Albadri, S., et al., *Extraction of first permanent molar teeth: results from three dental hospitals*. British dental journal, 2007. **203**(7): p. E14-E14.
65. Leppaniemi, A., P.-L. Lukinmaa, and S. Alaluusua, *Nonfluoride hypomineralizations in the permanent first molars and their impact on the treatment need*. Caries research, 2001. **35**(1): p. 36-40.
66. Skeie, M., et al., *The relationship between caries in the primary dentition at 5 years of age and permanent dentition at 10 years of age—a longitudinal study*. International Journal of Paediatric Dentistry, 2006. **16**(3): p. 152-160.
67. Angle, E.H., J. Grünberg, and A. Oppenheim, *Behandlung der Okklusionsanomalien der Zähne: Angle's system*. 1908: H. Meusser.
68. Risse, G., *The angulation of upper 1st permanent molars, the key to functional occlusion*. Artikel Fach J, 2005. **1**: p. 1-9.
69. Gupta, M., et al., *Diagnosis and management of a patient with congenitally missing maxillary first permanent molars: A rare case report*. Case Reports in Dentistry, 2016. **2016**.
70. KIRZIOĞLU, Z. and G. Begüm, *BİRİNCİ BÜYÜK AZI DIŞI ERKEN KAYBI VE ETKİLERİ–DERLEME*. Balıkesir Sağlık Bilimleri Dergisi, 2014. **3**(1): p. 41-44.
71. Anand, P.S., K.P. Kamath, and B. Nair, *Trends in extraction of permanent teeth in private dental practices in Kerala state, India*. J Contemp Dent Pract, 2010. **11**(3): p. 041-8.
72. Sandler, P.J., R. Atkinson, and A.M. Murray, *For four sixes*. American Journal of Orthodontics and Dentofacial Orthopedics, 2000. **117**(4): p. 418-434.
73. Travess, H., D. Roberts-Harry, and J. Sandy, *Orthodontics. Part 8: extractions in orthodontics*. British dental journal, 2004. **196**(4): p. 195-203.
74. Kuscu, O., N. Sandallı, and E. Caglar, *Azı-Kesici Hipomineralizasyonu (MIH): Tanı, tedavi ve koruyucu yöntemler*. Yeditepe Uni Dis Hek Fak Derg, 2007. **3**: p. 26-32.
75. MÜFTÜOĞLU, Ö. and T.U.T. MEMİKOĞLU, *ORTODONTİK TEDAVİDE DIŞ ÇEKİMİ DERLEME*.
76. Gill, D., R. Lee, and C. Tredwin, *Treatment planning for the loss of first permanent molars*. Dental update, 2001. **28**(6): p. 304-308.
77. Jälevik, B., et al., *Etiologic factors influencing the prevalence of demarcated opacities in permanent first molars in a group of Swedish children*. European journal of oral sciences, 2001. **109**(4): p. 230-234.
78. Weerheijm, K., B. Jalevik, and S. Alaluusua, *Molar-incisor hypomineralisation*. Caries research, 2001. **35**(5): p. 390.
79. Ong, D.V. and J. Bleakley, *Compromised first permanent molars: an orthodontic perspective*. Australian dental journal, 2010. **55**(1): p. 2-14.

80. Teo, T., et al., *The evaluation of spontaneous space closure after the extraction of first permanent molars*. European Archives of Paediatric Dentistry, 2013. **14**: p. 207-212.
81. Thunold, K. *Early loss of the first molars 25 years after*. in *Report of the congress. European Orthodontic Society*. 1970.
82. Wu, M., et al., *Is there sufficient evidence to support an optimum time for the extraction of first permanent molars?* European Archives of Paediatric Dentistry, 2017. **18**: p. 155-161.
83. Patel, S., P. Ashley, and J. Noar, *Radiographic prognostic factors determining spontaneous space closure after loss of the permanent first molar*. American Journal of Orthodontics and Dentofacial Orthopedics, 2017. **151**(4): p. 718-726.
84. White, S.C. and M.J. Pharoah, *Oral radiology-E-Book: Principles and interpretation*. 2014: Elsevier Health Sciences.
85. Plint, D. *The effect on the occlusion of the loss of one or more first permanent molars*. in *Report of the Congress. European Orthodontic Society*. 1970.
86. Telli, A. and A.S.B.B.A. Dişlerinin, *Zorunlu Erken Çekimine Bağlı Dental Arklarda Görülen Değişiklikler*. Türk Ort Derg, 1989. **2**: p. 138-43.
87. Cobourne, M., A. Williams, and R. McMullan, *A guideline for first permanent molar extraction in children*. The Royal College of Surgeons, 2009.
88. Cameron, A.C. and R.P. Widmer, *Handbook of pediatric dentistry*. 2013: Elsevier Health Sciences.
89. Eichenberger, M., et al., *The timing of extraction of non-restorable first permanent molars: a systematic review Introduction*. Eur J Paediatr Dent, 2015. **16**(4): p. 8-272.
90. Çağlaroğlu, M., N. Kilic, and A. Erdem, *Effects of early unilateral first molar extraction on skeletal asymmetry*. American journal of orthodontics and dentofacial orthopedics, 2008. **134**(2): p. 270-275.
91. Crabb, J. and W. Rock, *Treatment planning in relation to the first permanent molar*. British dental journal, 1971. **131**(9): p. 396-401.
92. Shroff, B. and S.M. Siegel. *Treatment of patients with asymmetries using asymmetric mechanics*. in *Seminars in Orthodontics*. 1998. Elsevier.
93. Telli, A. and S. Aytan, *Changes in the dental arch due to obligatory early extraction of first permanent molars*. Turk Ortodonti Dergisi: Ortodonti Derneği'nin Resmi Yayın Organidir= Turkish Journal of Orthodontics, 1989. **2**(1): p. 138-143.
94. Hotz, R.P., *Guidance of eruption versus serial extraction*. American Journal of Orthodontics, 1970. **58**(1): p. 1-20.
95. Saraç, O., *DAİMİ BİRİNCİ MOLAR DIŞ ÇEKİMİNDEN SONRA SPONTAN YER KAPANMASINI ETKİLEYEN FAKTÖRLERİN RADYOGRAFİK OLARAK İNCELENMESİ: BİR RETROSPEKTİF ÇALIŞMA*, P. Demir, Editor. 2020, T.C. İNÖNÜ ÜNİVERSİTESİ DİŞ HEKİMLİĞİ FAKÜLTESİ.
96. Bishara, S.E., et al., *Changes in the molar relationship between the deciduous and permanent dentitions: a longitudinal study*. American Journal of Orthodontics and Dentofacial Orthopedics, 1988. **93**(1): p. 19-28.
97. Daugaard-Jensen, I., *Extraction of first molars in discrepancy cases*. American Journal of Orthodontics, 1973. **64**(2): p. 115-136.
98. Cobourne, M., A. Williams, and M. Harrison, *National clinical guidelines for the extraction of first permanent molars in children*. British dental journal, 2014. **217**(11): p. 643-648.
99. Richardson, A., *Spontaneous changes in the incisor relationship following extraction of lower first permanent molars*. British Journal of Orthodontics, 1979. **6**(2): p. 85-90.
100. Hallett, G. and P. Burke, *Symmetrical extraction of first permanent molars. Factors controlling results in the lower arch*. Trans Eur Orthod Soc, 1961: p. 238-255.
101. Canpolat, M., *Daimi birinci büyük azı dişlerinde yapılan kontrollü çekimlerin klinik ve radyografik sonuçları*. 2020, [Doktora tezi]. Ankara: Ankara Üniversitesi.
102. Normando, A.D.C., et al., *Dentoalveolar changes after unilateral extractions of mandibular first molars and their influence on third molar development and position*. World journal of orthodontics, 2010. **11**(1).
103. Thilander, B. and S. Skagius. *Orthodontic sequelae of extraction of permanent first molars. A longitudinal study*. in *Report of the congress. European Orthodontic Society*. 1970.
104. Alkhadra, T., *A systematic review of the consequences of early extraction of first permanent first molar in different mixed dentition stages*. Journal of International Society of Preventive & Community Dentistry, 2017. **7**(5): p. 223.

105. Bell, G., *Use of dental panoramic tomographs to predict the relation between mandibular third molar teeth and the inferior alveolar nerve: Radiological and surgical findings, and clinical outcome*. British Journal of Oral and Maxillofacial Surgery, 2004. **42**(1): p. 21-27.
106. Gomes, A.C.A., et al., *Sensitivity and specificity of pantomography to predict inferior alveolar nerve damage during extraction of impacted lower third molars*. Journal of oral and maxillofacial surgery, 2008. **66**(2): p. 256-259.
107. Ozcan, I., *Diş Hekimliğinde Radyolojinin Esasları: Konvansiyonelden Dijitale*. 2017.
108. Russell, S.J., *Artificial intelligence a modern approach*. 2010: Pearson Education, Inc.
109. Haenlein, M. and A. Kaplan, *A brief history of artificial intelligence: On the past, present, and future of artificial intelligence*. California management review, 2019. **61**(4): p. 5-14.
110. Atav, A., *İlaçların diğer ilaçlarla etkileşimlerinin uzman sistem ile belirlenmesi*. 2020, Maltepe Üniversitesi, Fen Bilimleri Enstitüsü.
111. Arslan, K., *Eğitimde yapay zekâ ve uygulamaları*. Batı Anadolu Eğitim Bilimleri Dergisi, 2020. **11**(1): p. 71-88.
112. YILMAZ, D.Ö.Ü.A.a.K.Y., *Yapay Zeka 2021: KODLAB YAYIN DAĞITIM YAZILIM LTD. ŞTİ.*
113. Kocabaş, Ş., *Yapay zeka araştırma ve uygulama alanları*. Docplayer: <https://docplayer.biz.tr/3313838-Yapay-zeka-arastirma-ve-uygulama-alanlari.html> adresinden alındı, 2015.
114. MUMAY, B.S. and Ö. ERGÜVEN, *Artificial intelligence applications used in pharmacy and pharmacy related fields: Pharmacy and artificial intelligence*. Sağlık Bilimlerinde Yapay Zeka Dergisi (Journal of Artificial Intelligence in Health Sciences) ISSN: 2757-9646, 2021. **1**(2): p. 34-42.
115. Khanagar, S.B., et al., *Developments, application, and performance of artificial intelligence in dentistry—A systematic review*. Journal of dental sciences, 2021. **16**(1): p. 508-522.
116. Öztemel, E., *Yapay sinir ağları*. PapatyaYayincilik, İstanbul, 2003.
117. Nagi, R., et al., *Clinical applications and performance of intelligent systems in dental and maxillofacial radiology: A review*. Imaging Science in Dentistry, 2020. **50**(2): p. 81.
118. Alpaydin, E., *Machine learning: the new AI*. 2016: MIT press.
119. Alpaydin, E., *Introduction to machine learning*. 2020: MIT press.
120. Hoshino, Y. and K. Kamei. *A proposal of reinforcement learning system to use knowledge effectively*. in *SICE 2003 Annual Conference (IEEE Cat. No. 03TH8734)*. 2003. IEEE.
121. Kelleher, J.D., *Deep learning*. 2019: MIT press.
122. Xing, L., M.L. Giger, and J.K. Min, *Artificial intelligence in medicine: technical basis and clinical applications*. 2020: Academic Press.
123. Maltarollo, V.G., K.M. Honório, and A.B.F. da Silva, *Applications of artificial neural networks in chemical problems*. Artificial neural networks-architectures and applications, 2013: p. 203-223.
124. Öztürk, K. and M.E. Şahin, *Yapay sinir ağları ve yapay zekâ'ya genel bir bakış*. Takvim-i Vekayi, 2018. **6**(2): p. 25-36.
125. Krenker, A., J. Beşter, and A. Kos, *Introduction to the artificial neural networks*. Artificial Neural Networks: Methodological Advances and Biomedical Applications. InTech, 2011: p. 1-18.
126. Ağyar, Z., *Yapay sinir ağlarının kullanım alanları ve bir uygulama*. Mühendis ve Makine, 2015. **56**(662): p. 22-23.
127. Keskenler, M.F. and E.F. Keskenler, *Geçmişten günümüze yapay sinir ağları ve tarihçesi*. Takvim-i Vekayi, 2017. **5**(2): p. 8-18.
128. Çoruh, P.D.M., *Bilişim teknolojileri ekonomisi toplumu*. 2019: eKitap Projesi & Cheapest Books.
129. Kızrak, M.A. and B. Bolat, *Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma*. Bilişim Teknolojileri Dergisi, 2018. **11**(3): p. 263-286.
130. Deng, L. and D. Yu, *Foundations and Trends in Signal Processing: DEEP LEARNING—Methods and Applications*. 2014.
131. LeCun, Y., Y. Bengio, and G. Hinton, *Deep learning*. nature, 2015. **521**(7553): p. 436-444.
132. Shrestha, A. and A. Mahmood, *Review of deep learning algorithms and architectures*. IEEE access, 2019. **7**: p. 53040-53065.
133. DOĞAN, F. and İ. TÜRKÖĞLU, *Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme*. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 2019. **10**(2): p. 409-445.
134. Özkan, İ. and E. Ülker, *Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri*. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 2017. **6**(3): p. 85-104.

135. Zhao, Z.-Q., et al., *Object detection with deep learning: A review*. IEEE transactions on neural networks and learning systems, 2019. **30**(11): p. 3212-3232.
136. Putra, R.H., et al., *Current applications and development of artificial intelligence for digital dental radiography*. Dentomaxillofacial Radiology, 2022. **51**(1): p. 20210197.
137. Zhang, X., et al., *Research on scene classification method of high-resolution remote sensing images based on RFPNet*. Applied Sciences, 2019. **9**(10): p. 2028.
138. Liu, A.C.-C. and O.M.K. Law, *Artificial Intelligence Hardware Design: Challenges and Solutions*. 2021: John Wiley & Sons.
139. Srivastava, N., et al., *Dropout: a simple way to prevent neural networks from overfitting*. The journal of machine learning research, 2014. **15**(1): p. 1929-1958.
140. Goodfellow, I., Y. Bengio, and A. Courville, *Deep learning*. 2016: MIT press.
141. Wilson, A.C., et al., *The marginal value of adaptive gradient methods in machine learning*. Advances in neural information processing systems, 2017. **30**.
142. Gülcü, A. and K. Zeki, *Konvolüsyonel sinir ağlarında hiper-parametre optimizasyonu yöntemlerinin incelenmesi*. Gazi University Journal of Science Part C: Design and Technology, 2019. **7**(2): p. 503-522.
143. ALTUN, S. and M.F. TALU, *Derin sinir ağları için hiperparametre metodlarının ve kitlelerinin incelenmesi*. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 2021. **12**(2): p. 187-199.
144. KURT, F., *EVRIŞİMLİ SİNİR AĞLARINDA HİPER PARAMETRELERİN ETKİSİNİN İNCELENMESİ*, in *Bilgisayar Mühendisliği Anabilim Dalı 2018*, Hacettepe Üniversitesi. 145. LeCun, Y., et al., *Gradient-based learning applied to document recognition*. Proceedings of the IEEE, 1998. **86**(11): p. 2278-2324.
146. Krizhevsky, A., I. Sutskever, and G.E. Hinton, *Imagenet classification with deep convolutional neural networks*. Advances in neural information processing systems, 2012. **25**.
147. Zeiler, M.D. and R. Fergus, *Stochastic pooling for regularization of deep convolutional neural networks*. arXiv preprint arXiv:1301.3557, 2013.
148. Simonyan, K. and A. Zisserman, *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556, 2014.
149. Szegedy, C., et al. *Going deeper with convolutions*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015.
150. Russakovsky, O., et al., *Imagenet large scale visual recognition challenge*. International journal of computer vision, 2015. **115**: p. 211-252.
151. Milan, D., M. Jens, and V. Stefaan, *Artificial intelligence with deep learning in nuclear medicine and radiology*. EJMNM Physics, 2021. **8**(1).
152. Huang, G., et al. *Densely connected convolutional networks*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
153. Ronneberger, O., P. Fischer, and T. Brox. *U-net: Convolutional networks for biomedical image segmentation*. in *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18*. 2015. Springer.
154. EKER, A.G. and D. Nevcihan, *Medikal görüntü işlemede derin öğrenme uygulamaları*. Acta Infologica, 2021. **5**(2): p. 459-474.
155. Milletari, F., N. Navab, and S.-A. Ahmadi. *V-net: Fully convolutional neural networks for volumetric medical image segmentation*. in *2016 fourth international conference on 3D vision (3DV)*. 2016. Ieee.
156. Redmon, J., et al. *You only look once: Unified, real-time object detection*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
157. Jiang, P., et al., *A Review of Yolo algorithm developments*. Procedia Computer Science, 2022. **199**: p. 1066-1073.
158. Redmon, J. and A. Farhadi, *Yolov3: An incremental improvement*. arXiv preprint arXiv:1804.02767, 2018.
159. Jocher, G., et al., *Ultralytics/yolov5: v4. 0-nn. SiLU () activations, weights & biases logging, PyTorch hub integration*. Zenodo, 2021.
160. AĞDAŞ, M.T. and S. GÜLSEÇEN, *Güvenlik Kameralarında Otomatik Silah ve Bıçak Tespit Sistemi: Karşılaştırmalı YOLO Modelleri*. Avrupa Bilim ve Teknoloji Dergisi, 2022(41): p. 16-22.

161. Jocher, G., et al., *ultralytics/yolov5: v7. 0-yolov5 sota realtime instance segmentation*. Zenodo, 2022.
162. Toğaçar, M. and B. Ergen, *Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması*. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 2019. **31**(1): p. 109-121.
163. Özkan, İ. and E. ÜLKER, *Derin Öğrenmede Kullanılan Veri Setleri ve Yazılım Kütüphaneleri*.
164. Bergstra, J., et al. *Theano: Deep learning on gpus with python*. in *NIPS 2011, BigLearning Workshop, Granada, Spain*. 2011. Citeseer.
165. Elshawi, R., et al., *DLBench: a comprehensive experimental evaluation of deep learning frameworks*. Cluster Computing, 2021. **24**: p. 2017-2038.
166. Paskze, A. and S. Chintala, *Tensors and Dynamic neural networks in Python with strong GPU acceleration*. 2017, Jan.
167. Kim, M., et al., *Deep Learning in Medical Imaging*. Neurospine, 2019. **16**(4): p. 657-668.
168. Ker, J., et al., *Deep learning applications in medical image analysis*. Ieee Access, 2017. **6**: p. 9375-9389.
169. Hesamian, M.H., et al., *Deep learning techniques for medical image segmentation: achievements and challenges*. Journal of digital imaging, 2019. **32**: p. 582-596.
170. Kim, M., et al., *Deep learning in medical imaging*. Neurospine, 2019. **16**(4): p. 657.
171. Hung, K., et al., *The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review*. Dentomaxillofac Radiol, 2020. **49**(1): p. 20190107.
172. Schleyer, T.K., et al., *Clinical computing in general dentistry*. Journal of the American Medical Informatics Association, 2006. **13**(3): p. 344-352.
173. Begum, S., et al., *A case-based decision support system for individual stress diagnosis using fuzzy similarity matching*. Computational Intelligence, 2009. **25**(3): p. 180-195.
174. Mendonça, E.A., *Clinical decision support systems: perspectives in dentistry*. Journal of dental education, 2004. **68**(6): p. 589-597.
175. Tuzoff, D.V., et al., *Tooth detection and numbering in panoramic radiographs using convolutional neural networks*. Dentomaxillofacial Radiology, 2019. **48**(4): p. 20180051.
176. Leite, A.F., et al., *Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs*. Clinical oral investigations, 2021. **25**: p. 2257-2267.
177. Lee, J.-H., et al., *Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs*. Oral surgery, oral medicine, oral pathology and oral radiology, 2020. **129**(6): p. 635-642.
178. Muramatsu, C., et al., *Tooth detection and classification on panoramic radiographs for automatic dental chart filing: improved classification by multi-sized input data*. Oral Radiology, 2021. **37**: p. 13-19.
179. Chen, H., et al., *A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films*. Scientific reports, 2019. **9**(1): p. 3840.
180. Yasa, Y., et al., *An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs*. Acta Odontol Scand, 2021. **79**(4): p. 275-281.
181. Bilgir, E., et al., *An artificial intelligence approach to automatic tooth detection and numbering in panoramic radiographs*. BMC medical imaging, 2021. **21**: p. 1-9.
182. Miki, Y., et al., *Classification of teeth in cone-beam CT using deep convolutional neural network*. Computers in biology and medicine, 2017. **80**: p. 24-29.
183. Lee, J.-H., et al., *Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm*. Journal of dentistry, 2018. **77**: p. 106-111.
184. Schwendicke, F., et al., *Deep learning for caries lesion detection in near-infrared light transillumination images: A pilot study*. Journal of dentistry, 2020. **92**: p. 103260.
185. Cantu, A.G., et al., *Detecting caries lesions of different radiographic extension on bitewings using deep learning*. Journal of dentistry, 2020. **100**: p. 103425.
186. Bayraktar, Y. and E. Ayan, *Diagnosis of interproximal caries lesions with deep convolutional neural network in digital bitewing radiographs*. Clinical oral investigations, 2022. **26**(1): p. 623-632.
187. Hiraiwa, T., et al., *A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography*. Dentomaxillofacial Radiology, 2019. **48**(3): p. 20180218.

188. Jeon, S.-J., et al., *Deep-learning for predicting C-shaped canals in mandibular second molars on panoramic radiographs*. Dentomaxillofacial Radiology, 2021. **50**(5): p. 20200513.
189. Takahashi, T., et al., *Deep learning-based detection of dental prostheses and restorations*. Scientific Reports, 2021. **11**(1): p. 1960.
190. Endres, M.G., et al., *Development of a deep learning algorithm for periapical disease detection in dental radiographs*. Diagnostics, 2020. **10**(6): p. 430.
191. Ekert, T., et al., *Deep learning for the radiographic detection of apical lesions*. Journal of endodontics, 2019. **45**(7): p. 917-922. e5.
192. Orhan, K., et al., *Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans*. International endodontic journal, 2020. **53**(5): p. 680-689.
193. Lee, J.-H., et al., *Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm*. Journal of periodontal & implant science, 2018. **48**(2): p. 114-123.
194. Chang, H.-J., et al., *Deep learning hybrid method to automatically diagnose periodontal bone loss and stage periodontitis*. Scientific reports, 2020. **10**(1): p. 7531.
195. Krois, J., et al., *Deep learning for the radiographic detection of periodontal bone loss*. Scientific reports, 2019. **9**(1): p. 8495.
196. Sevda, K., et al., *Success of artificial intelligence system in determining alveolar bone loss from dental panoramic radiography images*. Cumhuriyet Dental Journal, 2020. **23**(4): p. 318-324.
197. Kim, J., et al., *DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs*. Scientific reports, 2019. **9**(1): p. 17615.
198. Vinayahalingam, S., et al., *Automated detection of third molars and mandibular nerve by deep learning*. Sci Rep, 2019. **9**(1): p. 9007.
199. Kwak, G.H., et al., *Automatic mandibular canal detection using a deep convolutional neural network*. Scientific Reports, 2020. **10**(1): p. 5711.
200. Fukuda, M., et al., *Comparison of 3 deep learning neural networks for classifying the relationship between the mandibular third molar and the mandibular canal on panoramic radiographs*. Oral surgery, oral medicine, oral pathology and oral radiology, 2020. **130**(3): p. 336-343.
201. Jaskari, J., et al., *Deep learning method for mandibular canal segmentation in dental cone beam computed tomography volumes*. Scientific reports, 2020. **10**(1): p. 5842.
202. Kuwada, C., et al., *Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs*. Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology, 2020. **130**(4): p. 464-469.
203. Kwon, O., et al., *Automatic diagnosis for cysts and tumors of both jaws on panoramic radiographs using a deep convolution neural network*. Dentomaxillofacial Radiology, 2020. **49**(8): p. 20200185.
204. Poedjiastoeti, W. and S. Suebnukarn, *Application of convolutional neural network in the diagnosis of jaw tumors*. Healthcare informatics research, 2018. **24**(3): p. 236-241.
205. Yang, H., et al., *Deep learning for automated detection of cyst and tumors of the jaw in panoramic radiographs*. Journal of clinical medicine, 2020. **9**(6): p. 1839.
206. Lee, J.H., D.H. Kim, and S.N. Jeong, *Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network*. Oral diseases, 2020. **26**(1): p. 152-158.
207. Murata, M., et al., *Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography*. Oral radiology, 2019. **35**: p. 301-307.
208. Kuwana, R., et al., *Performance of deep learning object detection technology in the detection and diagnosis of maxillary sinus lesions on panoramic radiographs*. Dentomaxillofacial Radiology, 2021. **50**(1): p. 20200171.
209. Mori, M., et al., *A deep transfer learning approach for the detection and diagnosis of maxillary sinusitis on panoramic radiographs*. Odontology, 2021. **109**: p. 941-948.
210. Lee, J.-S., et al., *Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminary study*. Dentomaxillofacial Radiology, 2019. **48**(1): p. 20170344.
211. Lee, K.-S., et al., *Evaluation of transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs*. Journal of clinical medicine, 2020. **9**(2): p. 392.


212. Kim, J.-E., et al., *Transfer learning via deep neural networks for implant fixture system classification using periapical radiographs*. Journal of clinical medicine, 2020. **9**(4): p. 1117.
213. Lee, J.-H. and S.-N. Jeong, *Efficacy of deep convolutional neural network algorithm for the identification and classification of dental implant systems, using panoramic and periapical radiographs: A pilot study*. Medicine, 2020. **99**(26).
214. Takahashi, T., et al., *Identification of dental implants using deep learning—pilot study*. International journal of implant dentistry, 2020. **6**: p. 1-6.
215. Kim, H., et al., *Web-based fully automated cephalometric analysis by deep learning*. Computer methods and programs in biomedicine, 2020. **194**: p. 105513.
216. Kunz, F., et al., *Artificial intelligence in orthodontics: Evaluation of a fully automated cephalometric analysis using a customized convolutional neural network*. Journal of Orofacial Orthopedics/Fortschritte der Kieferorthopädie, 2020. **81**(1).
217. Ariji, Y., et al., *Automatic detection of cervical lymph nodes in patients with oral squamous cell carcinoma using a deep learning technique: a preliminary study*. Oral Radiology, 2021. **37**: p. 290-296.
218. Fu, Q., et al., *A deep learning algorithm for detection of oral cavity squamous cell carcinoma from photographic images: A retrospective study*. EClinicalMedicine, 2020. **27**.
219. Kim, D.W., et al., *Deep learning-based survival prediction of oral cancer patients*. Scientific reports, 2019. **9**(1): p. 6994.
220. Categorical, A., *Glossary of terms*. Machine Learning, 1998. **30**(2): p. 271-274.
221. Davis, J. and M. Goadrich. *The relationship between Precision-Recall and ROC curves*. in *Proceedings of the 23rd international conference on Machine learning*. 2006.
222. Craven, M. and J. Bockhorst, *Markov networks for detecting overlapping elements in sequence data*. Advances in Neural Information Processing Systems, 2004. **17**.
223. Bunescu, R., et al., *Comparative experiments on learning information extractors for proteins and their interactions*. Artificial intelligence in medicine, 2005. **33**(2): p. 139-155.
224. Demir, P. and A. Evren, *Koruyucu ve Durdurucu Pedodonti ve Ortodonti Uygulamaları*. 2021: Livre de Lyon.
225. Kırzioğlu, Z. and D. Ceyhan, *Erken 6 yaş dişi çekim zamanı! 15*. Türk Pedodonti Derneği Kongresi, 2007: p. 17-21.
226. YAŞAR, Z.F., *DİŞLERDEN YAŞ TAHMİNİ METOTLARI: DERLEME*. SAĞLIK BİLİMLERİNDE: p. 7.
227. Olze, A., et al., *Validation of common classification systems for assessing the mineralization of third molars*. International journal of legal medicine, 2005. **119**: p. 22-26.
228. Dhanjal, K., M. Bhardwaj, and H. Liversidge, *Reproducibility of radiographic stage assessment of third molars*. Forensic science international, 2006. **159**: p. S74-S77.
229. Kullman, L., *Accuracy of two dental and one skeletal age estimation method in Swedish adolescents*. Forensic science international, 1995. **75**(2-3): p. 225-236.
230. Harris, M. and C. Nortje, *The mesial root of the third mandibular molar. A possible indicator of age*. The Journal of forensic odonto-stomatology, 1984. **2**(2): p. 39-43.
231. Pintana, P., et al., *Fully automated method for dental age estimation using the ACF detector and deep learning*. Egyptian Journal of Forensic Sciences, 2022. **12**(1): p. 54.
232. Teo, T.K.-Y., P.F. Ashley, and D. Derrick, *Lower first permanent molars: developing better predictors of spontaneous space closure*. European journal of orthodontics, 2016. **38**(1): p. 90-95.
233. Fadel, H.T., et al., *Are artificial neural networks useful for predicting overhanging dental restorations? a cross-sectional study*. World Journal of Dentistry, 2020. **11**(2): p. 99-104.
234. Karatas, O., et al., *A deep learning approach to dental restoration classification from bitewing and periapical radiographs*. Quintessence Int, 2021. **52**: p. 568-574.
235. Kyventidis, N. and C. Angelopoulos, *Intraoral radiograph anatomical region classification using neural networks*. International Journal of Computer Assisted Radiology and Surgery, 2021. **16**: p. 447-455.
236. Cha, J.-Y., et al., *Peri-implant bone loss measurement using a region-based convolutional neural network on dental periapical radiographs*. Journal of clinical medicine, 2021. **10**(5): p. 1009.
237. Kılıç, M.C., et al., *Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs*. Dentomaxillofacial Radiology, 2021. **50**(6): p. 20200172.
238. Fukuda, M., et al., *Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography*. Oral Radiology, 2020. **36**: p. 337-343.

239. Patil, V., et al., *Artificial neural network for gender determination using mandibular morphometric parameters: A comparative retrospective study*. Cogent Engineering, 2020. **7**(1): p. 1723783.
240. Sukegawa, S., et al., *Multi-task deep learning model for classification of dental implant brand and treatment stage using dental panoramic radiograph images*. Biomolecules, 2021. **11**(6): p. 815.
241. Son, D.-M., et al., *Automatic detection of mandibular fractures in panoramic radiographs using deep learning*. Diagnostics, 2021. **11**(6): p. 933.
242. Chen, Y., et al., *Automatic segmentation of individual tooth in dental CBCT images from tooth surface map by a multi-task FCN*. IEEE Access, 2020. **8**: p. 97296-97309.
243. Choi, H.-I., et al., *Artificial intelligent model with neural network machine learning for the diagnosis of orthognathic surgery*. Journal of Craniofacial Surgery, 2019. **30**(7): p. 1986-1989.
244. Kurt Bayrakdar, S., et al., *A deep learning approach for dental implant planning in cone-beam computed tomography images*. BMC Medical Imaging, 2021. **21**(1): p. 86.
245. Sin, Ç., et al., *A deep learning algorithm proposal to automatic pharyngeal airway detection and segmentation on CBCT images*. Orthodontics & Craniofacial Research, 2021. **24**: p. 117-123.
246. Sen, D., et al., *Artificial intelligence and the radiologist: the future in the Armed Forces Medical Services*. BMJ Mil Health, 2020. **166**(4): p. 254-256.
247. Ueda, D., A. Shimazaki, and Y. Miki, *Technical and clinical overview of deep learning in radiology*. Japanese journal of radiology, 2019. **37**: p. 15-33.
248. Langlotz, C.P., *Will artificial intelligence replace radiologists?* 2019, Radiological Society of North America. p. e190058.
249. Pesapane, F., M. Codari, and F. Sardanelli, *Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine*. European radiology experimental, 2018. **2**: p. 1-10.
250. Banar, N., et al., *Towards fully automated third molar development staging in panoramic radiographs*. Int J Legal Med, 2020. **134**(5): p. 1831-1841.
251. Aljameel, S.S., et al., *Predictive Artificial Intelligence Model for Detecting Dental Age Using Panoramic Radiograph Images*. Big Data and Cognitive Computing, 2023. **7**(1): p. 8.
252. Shaheen, E., et al., *A novel deep learning system for multi-class tooth segmentation and classification on cone beam computed tomography. A validation study*. Journal of Dentistry, 2021. **115**: p. 103865.
253. Widiastri, M., et al., *Dental-yolo: Alveolar bone and mandibular canal detection on cone beam computed tomography images for dental implant planning*. IEEE Access, 2022. **10**: p. 101483-101494.
254. Celik, M.E., *Deep learning based detection tool for impacted mandibular third molar teeth*. Diagnostics, 2022. **12**(4): p. 942.
255. Mohammad, N., et al., *Accuracy of advanced deep learning with tensorflow and keras for classifying teeth developmental stages in digital panoramic imaging*. BMC Medical Imaging, 2022. **22**(1): p. 66.
256. Silva, G., L. Oliveira, and M. Pithon, *Automatic segmenting teeth in X-ray images: Trends, a novel data set, benchmarking and future perspectives*. Expert Systems with Applications, 2018. **107**: p. 15-31.



8. EKLER

Evrak Tarih ve Sayısı: 14.06.2023-111201

 **BEZMİALEM**
VAKIF ÜNİVERSİTESİ

T.C.
BEZMİALEM VAKIF ÜNİVERSİTESİ REKTÖRLÜĞÜ
Teknoloji Transfer Ofisi
Etik Kurullar Birimi

Sayı : E-54022451-050.05.04-111201
Konu : 2022/394 Etik Kurul Kararı

14.06.2023

Sayın Dr. Öğr. Üyesi İrfan SARICA
Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Başkanlığı - Doktor Öğretim Üyesi

2022/394 numaralı "Daimi Dentisyonda Mandibular İkinci Molar Dişlerin Kök Oluşum Seviyelerinin Yapay Zeka ile Değerlendirilerek Çekim Endikasyonu Olan Birinci Molar Dişlerin İdeal Çekim Zamanının Belirlenmesi" başlıklı başvurunuz Üniversitemiz Etik Kurullar Birimi'nin 07.06.2023 tarihli, 11 sayılı Girişimsel Olmayan Araştırmalar Etik Kurul toplantısında değerlendirilmiş olup, mevcudun oy birliğiyle onaylanmasına karar verilmiştir.

Bilgilerinizi ve gereğini arz/rica ederim.


Prof.Dr. Hayrettin ÖZTÜRK
Girişimsel Olmayan Araştırmalar Etik
Kurulu Başkanı

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Doğrulama Kodu :BSP42MZ1TP Pin Kodu :45782 Belge Takip Adresi : <https://turkiye.gov.tr/ebd?ek=5394&cd=BSP42MZ1TP&eS=111201>

Bezmialem Vakıf Üniversitesi Adnan Menderes Bulvarı (Vatan Caddesi)
Fatih/İstanbul
Telefon No:0 (212) 523 22 88 Faks No:0 (212) 533 23 36
e-Posta:info@bezmialem.edu.tr İnternet Adresi:www.bezmialem.edu.tr

Bilgi için: Zübeyde ÖZDEMİR
Unvan: Sorumlu



Bu belge, güvenli elektronik imza ile imzalanmıştır.