

T.C.

RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ

DİŞ HEKİMLİĞİ FAKÜLTESİ

DERİN ÖĞRENME YÖNTEMİ KULLANILARAK GELİŞTİRİLEN
YAPAY ZEKÂ UYGULAMALARI ARACILIĞIYLA PANORAMİK
RADYOGRAFİDEN DİŞ YAŞININ TESPİTİ İLE DEMİRJIAN DİŞ
YAŞI BELİRLEME YÖNTEMİNİN KIYASLANMASI

Dt. Sude GÜMÜŞ

Çocuk Diş Hekimliği Ana Bilim Dalı

Uzmanlık Tezi

Tez Danışmanı
Doç. Dr. Ayça KURT

RİZE-2025

T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

**DERİN ÖĞRENME YÖNTEMİ KULLANILARAK GELİŞTİRİLEN
YAPAY ZEKÂ UYGULAMALARI ARACILIĞIYLA PANORAMİK
RADYOGRAFİDEN DİŞ YAŞININ TESPİTİ İLE DEMİRJIAN DİŞ
YAŞI BELİRLEME YÖNTEMİNİN KIYASLANMASI**

Dt. Sude GÜMÜŞ

Çocuk Diş Hekimliği Ana Bilim Dalı
Uzmanlık Tezi

Tez Danışmanı
Doç. Dr. Ayça KURT

RİZE-2025

KABUL ve ONAY

Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalında, Dr. Öğr. Ayça KURT danışmanlığında, Sude GÜMÜŞ tarafından hazırlanan Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zekâ Uygulamaları Aracılığıyla Panoramik Radyografiden Diş Yaşının Tespiti İle Demirjian Diş Yaşı Belirleme Yönteminin Kıyaslanması adlı bu tez çalışması 30.05.2025 tarihinde yapılan savunma sınavı sonucu oy birliğiyle başarılı bulunmuş ve jürimiz tarafından **Uzmanlık Tezi** olarak kabul edilmiştir.

Jüri Üyeleri

Unvan, Adı Soyadı

Başkan

: Doç. Dr. Yıldırım ERDOĞAN

Üye

: Doç. Dr. Ayça KURT

Üye

: Doç. Dr. Sema AYDINOĞLU

ETİK BEYAN

Çocuk Diş Hekimliği Programından mezun olmak üzere teslim ettiğim “Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zekâ Uygulamaları Aracılığıyla Panoramik Radyografiden Diş Yaşının Tespiti İle Demirjian Diş Yaşı Belirleme Yönteminin Kıyaslanması” adlı tezim, bilim ve araştırma etiği prensiplerine riayet edilerek tarafımdan yazılmıştır.

Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada:

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Sude GÜMÜŞ

30.05.2025

TEŞEKKÜR

Uzmanlık eğitimim süresince engin bilgi ve tecrübesiyle bana rehberlik eden; akademik gelişimime katkıları, yapıcı yönlendirmeleri ve her zaman sergilediği destekleyici yaklaşımıyla yanımda olan kıymetli hocam ve tez danışmanım Doç. Dr. Ayça KURT'a,

Uzmanlık eğitimi sürecimde bilgi ve tecrübelerinden faydalanma imkânı bulduğum değerli hocam Doç. Dr. Sema AYDINOĞLU'na,

Bölümümüzün değerli hocaları Öğr. Gör. İrem OKUMUŞ ve Öğr. Gör. Sena SAKIN ULUBAY'a,

Asistanlık eğitimim boyunca desteklerini her zaman yanımda hissettiğim, birlikte nice zorluğun üstesinden gelip güzel anılar biriktirdiğimiz sevgili arkadaşlarım Kader BİÇENGİL, Hande MÜSLÜMOĞLU, Feyza Nur BADEMLİ ve kıdemlilerim başta olmak üzere; katkı ve dayanışmalarıyla bu süreci daha anlamlı kılan tüm çalışma arkadaşlarıma,

Hayatım boyunca attığım her adımda bana güvenen, sevgi ve inancıyla daima yanımda olan sevgili annem Ayşe GÜMÜŞ'e, desteğini her zaman hissettiren sevgili babam Hakkı GÜMÜŞ'e ve varlığıyla bana güç veren sevgili kardeşim Dila GÜMÜŞ'e,

Bu çalışmada TSA 2024-1626 nolu proje desteği ile maddi olarak destek veren Recep Tayyip Erdoğan Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğüne,

Sonsuz sevgi ve teşekkürlerimi sunarım.

Dt. Sude GÜMÜŞ

İÇİNDEKİLER

KABUL ve ONAY.....	
ETİK BEYAN	I
TEŞEKKÜR.....	II
ÖZET	VII
ABSTRACT	VIII
SİMGELER ve KISALTMALAR DİZİNİ.....	IX
TABLolar DİZİNİ	XI
ŞEKİLLER DİZİNİ	XIII
1. GİRİŞ.....	1
2. GENEL BİLGİLER.....	4
2.1. Dişlerin Gelişimi	4
2.1.1. Mine Dokusu ve Gelişimi.....	6
2.1.2. Dentin Dokusu ve Gelişimi.....	7
2.1.3. Sement Dokusu ve Gelişimi	7
2.1.4. Pulpa Dokusu ve Gelişimi	8
2.1.5. Kök Gelişimi ve Biçimlenmesi	8
2.1.5. Periodontal ligament ve Gelişimi.....	8
2.1.6. Diş Sürmesi.....	9
2.2. Diş Sürme Zamanları	10
2.2.1. Süt Dişlenme Dönemi.....	10
2.2.2. Karışık Dişlenme Dönemi	12

2.2.3. Daimî Dişlenme Dönemi	13
2.3. Yaş Tayini ve Önemi	14
2.4. Çocuklarda ve Adelösanlarda Diş Yaşı Belirleme Yöntemleri.....	15
2.4.1. Schour ve Massler Yöntemi.....	15
2.4.2. Gleiser ve Hunt Yöntemi	15
2.4.3. Nolla Yöntemi.....	15
2.4.4. Haavikko Yöntemi	16
2.4.5. Moorrees, Fanning ve Hunt Yöntemi.....	16
2.4.6. Anderson, Thomson ve Popovich Yöntemi.....	16
2.4.7. Mörnstaad, Staaf ve Welande Yöntemi.....	16
2.4.8. Demirjian Yöntemi.....	17
2.4.9. Willems Yöntemi	19
2.4.10. Cameriere Yöntemi	19
2.4.11. Londra Atlas Yöntemi	20
2.4.12. Yapay Zekâ Uygulamaları	20
2.5. Yapay zekâ	20
2.5.1 Yapay Zekâ Yaklaşımları	21
2.5.1.1 Uzman Sistemler.....	22
2.5.1.2 Bulanık Mantık	22
2.5.1.3 Genetik Algoritmalar	23
2.5.1.4 Yapay Sinir Ağları.....	23
2.5.2 Makine Öğrenimi	27

2.5.3 Derin Öğrenme.....	28
2.5.3.1 Derin Öğrenmede Kullanılan Yapay Sinir Ağı Modelleri.....	29
2.5.3.2 Derin Öğrenme Tabanlı Görüntü Analiz Teknikleri ve Algoritmaları	33
2.5.3.3 Derin Öğrenme Kütüphaneleri	38
2.5.4 Diş Hekimliğinde Yapay Zekâ Uygulamaları	39
2.5.5 Yapay Zekâ Uygulamalarının Sınırlamaları	40
3. GEREÇ ve YÖNTEM.....	42
3.1. Çalışma Dizaynı	42
3.2 Etik Kurul Onayı	43
3.3. Veri Setinin Oluşturulması.....	43
3.4. Radyografik Görüntülerin Ön İşlemesi.....	44
3.5. Panoramik Radyografiler Üzerinde Demirjian Yöntemine Göre Diş Gelişim Evrelerinin Eğitim Verisi Olarak Etiketlenmesi	45
3.6. YOLOv8x Modeli Eğitim Aşaması.....	45
3.7. Yapay Zekâ Modelinin Doğruluk Değerlendirmesi	49
3.8. Yapay Zekâ ve Gözlemciler Tarafından Gerçekleştirilen Diş Gelişimi Etiketlemeleri ve Kıyaslanması.....	53
3.9. Kronolojik Yaşın Hesaplanması.....	54
3.10. Diş Yaşının Hesaplanması	55
3.11. İstatistiksel Analiz	59
4. BULGULAR.....	60

4.1. Yapay Zekâ Modelinin Performans Değerlendirmesi	60
4.1.1. Segmentasyon (Mask) Tabanlı Performans Analizi.....	61
4.1.2. Nesne Tespiti (Box) Tabanlı Performans Analizi.....	66
4.1.3. Karışıklık Matrisi	70
4.1.4. Eğitim Süreci ve Kayıp Fonksiyonları (Loss ve Metrikler)	73
4.2. Gözlemciler Arası Gelişim Evresi Kıyaslaması	74
4.2.1. Yapay Zekâ – Uzman Hekim Karşılaştırması	74
4.2.2. Yapay Zekâ – Araştırma Görevlisi Karşılaştırması	76
4.2.3. Gözlemciler Arası Kıyaslama ve Model Performansının Değerlendirilmesi.....	77
4.3. Diş Yaşı Tahminlerinin İstatistiksel Olarak Karşılaştırılması	79
5.TARTIŞMA.....	87
6. SONUÇ ve ÖNERİLER.....	100
KAYNAKLAR.....	102
EKLER.....	116
EK-1 Öz Geçmiş	116
EK-2 Etik Kurul Onay Formu.....	117
EK-3 Dekanlık İzin Belgesi.....	118
EK-4 İntihal Raporu	119

ÖZET

Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zekâ Uygulamaları Aracılığıyla Panoramik Radyografiden Diş Yaşının Tespiti ile Demirjian Diş Yaşı Belirleme Yönteminin Kıyaslanması

Amaç: Bu çalışmanın amacı, çocuklara ait panoramik radyografilerden Demirjian yöntemiyle etiketlenen diş gelişim evrelerini kullanarak geliştirilen derin öğrenme tabanlı yapay zekâ modelinin diş yaşı tahminindeki performansını değerlendirmek ve bu modelin, aynı yöntemi manuel olarak uygulayan uzman ve araştırma görevlisi ile doğruluk ve güvenilirlik açısından karşılaştırılmasını sağlamaktır.

Gereç ve Yöntem: Retrospektif tanımlayıcı tasarıma sahip bu çalışmada, 5–14 yaş aralığındaki çocuklara ait 1910 panoramik radyografi değerlendirilmiştir. Mandibular sol daimi dişler Demirjian yöntemine göre manuel olarak etiketlenmiş ve veriler, YOLOv8x tabanlı CranioCatch yazılımıyla geliştirilen yapay zekâ modeline öğretilmiştir. Modelin segmentasyon, nesne tespiti ve sınıflandırma performansı analiz edilmiş; diş yaşı tahminleri çocuk diş hekimi uzmanı, araştırma görevlisi ve yapay zekâ tarafından hesaplanarak istatistiksel olarak karşılaştırılmıştır.

Bulgular: Yapay zekâ modeli, diş gelişim evrelerini sınıflandırmada orta düzeyde bir başarı sergilemiştir. Kadın bireylerde yöntemler arasında anlamlı fark saptanmazken, erkek bireylerde yapay zekâ ve araştırma görevlisi tarafından etiketlenen gelişim evrelerinden hesaplanan diş yaşları, kronolojik yaştan anlamlı biçimde yüksek bulunmuştur ($p<0,05$). Bununla birlikte, yapay zekâ modeli genel olarak diğer gözlemcilerle kıyasla daha yüksek diş yaşı değerleri üretmiştir. Tüm gözlemciler arasında yüksek düzeyde uyum gözlenmiştir ($ICC=0,927$).

Sonuç: Çalışma sonuçlarımıza göre Demirjian yöntemine dayalı yapay zekâ modeli, diş yaşı tahmininde ortalama düzeyde farklılık göstermiş olsa da, yöntemler arasında yüksek düzeyde gözlemci uyumu saptanmıştır. Bu çalışma, derin öğrenme algoritmalarının diş yaşı tahmininde destekleyici bir araç olarak potansiyel taşıdığını, ancak daha ileri boyutlu çalışmalarla model doğruluğunun artırılması ve sınıf bazlı performansın iyileştirilmesi gerektiğini göstermektedir.

Anahtar Kelimeler: Çocuk diş hekimliği, Demirjian yöntemi, Derin öğrenme, Diş yaşı tahmini, Yapay zekâ, YOLOv8x

ABSTRACT

Comparison of Dental Age Estimation from Panoramic Radiographs Using Deep Learning-Based Artificial Intelligence Applications and the Demirjian Method

Aim: The aim of this study is to evaluate the performance of a deep learning-based artificial intelligence (AI) model, developed using tooth development stages labeled according to the Demirjian method on pediatric panoramic radiographs, in estimating dental age. Additionally, the study aims to compare the model's accuracy and reliability with those of expert and researcher observers who applied the same method manually.

Materials and Methods: In this retrospective descriptive study, 1,910 panoramic radiographs of children aged 5 to 14 were evaluated. The mandibular left permanent teeth were manually labeled according to the Demirjian method, and the data were used to train an AI model developed with YOLOv8x-based CranioCatch software. The model's performance in segmentation, object detection, and classification was analyzed. Dental age estimations were calculated by a pediatric dentistry specialist, a research assistant, and the AI model, and statistically compared.

Results: The AI model demonstrated a moderate level of success in classifying dental development stages. While no significant difference was found between methods in female subjects, the dental ages estimated from the stages labeled by the AI and the researcher were significantly higher than the chronological age in male subjects ($p < 0,05$). Overall, the AI model tended to produce higher dental age values compared to the human observers. A high level of inter-observer agreement was observed among all evaluators ($ICC = 0,927$).

Conclusion: According to the results of this study, although the AI model based on the Demirjian method showed an average level of variation in dental age estimation, a high level of inter-observer agreement was found across all methods. This study suggests that deep learning algorithms have potential as supportive tools in dental age estimation; however, further studies are needed to enhance model accuracy and improve class-specific performance.

Keywords: Artificial intelligence, Deep learning, Demirjian method, Dental age estimation, Pediatric dentistry, YOLOv8x

SİMGELER ve KISALTMALAR DİZİNİ

AI	: Artificial Intelligence
ark.	: Arkadaşları
Bkz.	: Bakınız
CBCT	: Konik Işımlı Bilgisayarlı Tomografi
CNN	: Convolutional Neural Network (Evrişimli Sinir Ağı)
ÇKA	: Çok Katmanlı Algılayıcılar
DİA	: Derin İnanç Ağları
ESA	: Evrişimli Sinir Ağı
GP	: Gerçek Pozitif
HERS	: Hertwig Epitel Kök Kılıfı
ICC	: Sınıf İçi Korelasyon Katsayısı
IoU	: Birleşim Üzerinden Ortalama Kesişme
İU	: İntrauterin Dönem
KGT	: Kuron Gelişiminin Tamamlanması
KT	: Kök Gelişiminin Tamamlanması
kVp	: Kilovolt peak
mA	: Miliamper
mAP	: Genel Ortalama Kesinlik
M	: Medyan

Ort	: Ortalama
PDL	: Periodontal Ligament
SBM	: Sınırlı Boltzman Makineleri
SDO	: Sert Doku Oluşumu
Sn	: Saniye
SPSS	: Statistical Package for the Social Sciences
SS	: Standart Sapma
SSD	: Single Shot MultiBox Detector
Wn	: Ağırlık Katsayısı
Xn	: Giriş
YOLO	: You Look Only Once
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı
YZ	: Yapay Zekâ
%	: Yüzde
μm	: Mikrometre

TABLÖLAR DİZİNİ

Tablo 1. Maksilladaki Süt Dişlerinin Gelişim Zamanları.....	11
Tablo 2. Mandibuladaki Süt Dişlerinin Gelişim Zamanları.....	11
Tablo 3. Maksilladaki Sürekli Dişlerin Gelişim Zamanları.....	13
Tablo 4. Mandibuladaki Sürekli Dişlerin Gelişim Zamanları.....	13
Tablo 5. Demirjian Yöntemine Göre Diş Gelişim Evreleri ve Tahmini Yaş Aralıkları ...	18
Tablo 6. Demirjian yöntemine göre 31–37 numaralı dişler için erkek bireylerde gelişim evrelerine karşılık gelen skor değerleri	55
Tablo 7. Demirjian yöntemine göre 31–37 numaralı dişler için kız bireylerde gelişim evrelerine karşılık gelen skor değerleri	56
Tablo 8. Demirjian yöntemine göre erkek bireylerde toplam skora karşılık gelen diş yaşı değerleri	57
Tablo 9. Demirjian yöntemine göre kız bireylerde toplam skora karşılık gelen diş yaşı değerleri	58
Tablo 10. AI–Uzman Hekim ve AI–Araştırma Görevlisi Karşılaştırmasına Ait Precision, Recall ve F1 Skorları.....	77
Tablo 11. Çalışmaya Dahil Edilen Katılımcıların Cinsiyete Göre Dağılımı	79
Tablo 12. Kronolojik Yaş ve Diş Yaş Tahminlerine Ait Tanımlayıcı İstatistikler	80
Tablo 13. Kronolojik ve Diş Yaşı Tahminlerine Ait İstatistiksel Karşılaştırma Sonuçları	81
Tablo 14. Post Hoc Bonferroni analizi sonuçları	82
Tablo 15. Cinsiyete göre farklı gözlemciler tarafından yapılan yaş tahminlerinin karşılaştırılması	83
Tablo 16. Cinsiyeti erkek olan katılımcılara göre Post Hoc Bonferroni analizi sonuçları	85

Tablo 17. Ölçümlerin sınıf içi korelasyon katsayısı (ICC) sonuçları85

Tablo 18. Ölçümlerin cinsiyete göre sınıf içi korelasyon katsayısı (ICC) sonuçları86



ŞEKİLLER DİZİNİ

Şekil 1. Demirjian Diş Gelişim Evreleri.....	18
Şekil 2. Biyolojik Nöronun ve Yapay Sinir Ağı Nöronunun Karşılaştırmalı Yapısı	24
Şekil 3. YOLOv8x modeline ait eğitim veri setinden örnek görüntüler	47
Şekil 4. Doğrulama veri setinde yapay zekâ modelinin tahmin çıktılarından örnekler ..	48
Şekil 5. Kesinlik (Precision) Formülü	51
Şekil 6. Duyarlılık (Recall) Formülü.....	51
Şekil 7. F1 Skoru Formülü.....	51
Şekil 8. Geliştirilen yapay zekâ modeline ait Mask Precision–Recall (Kesinlik–Duyarlılık) eğrisi	62
Şekil 9. Geliştirilen yapay zekâ modeline ait Mask F1–Confidence eğrisi.....	63
Şekil 10. Geliştirilen yapay zekâ modeline ait Mask Precision–Confidence eğrisi.....	64
Şekil 11. Geliştirilen yapay zekâ modeline ait Mask Recall–Confidence eğrisi	65
Şekil 12. Geliştirilen yapay zekâ modeline ait Box Precision–Recall (Kesinlik–Duyarlılık) eğrisi	67
Şekil 13. Geliştirilen yapay zekâ modeline ait Box F1–Confidence eğrisi	68
Şekil 14. Geliştirilen yapay zekâ modeline ait Box Precision–Confidence eğrisi.....	69
Şekil 15. Geliştirilen yapay zekâ modeline ait Box Recall–Confidence eğrisi	70
Şekil 16. Modelin sınıflandırma başarısına ait Confusion Matrix	71
Şekil 17. Modelin sınıflandırma başarısına ait Normalized Confusion Matrix	72
Şekil 18. YOLOv8x modelinin eğitim sürecine ait kayıp ve başarı metriklerinin epoch bazında ilerleyişi	73
Şekil 19. AI–Uzman ve AI–Araştırma Görevlisi karşılaştırmasında temel sınıflandırma metrikleri.....	78

1. GİRİŞ

Yaş tayini, çocuk diş hekimliği ve ortodonti alanlarında doğru tanı koymak ve uygun tedavi planlaması yapmak açısından büyük önem taşımaktadır.¹ Ancak bireyler arasında gözlenen gelişimsel farklılıklar nedeniyle, kronolojik yaş ile biyolojik yaş her zaman örtüşmeyebilmektedir. İskelet yaşı, diş yaşı, menarş yaşı, somatik olgunluk düzeyi, cinsel gelişim evreleri, boy ve kilo gibi göstergeler; çocukların büyüme ve gelişim süreçlerinin değerlendirilmesi ve biyolojik yaş tahmini amacıyla yaygın biçimde kullanılmaktadır.² Bu göstergeler arasında diş yaşı, biyolojik olgunluğu yansıtmaya açısından daha güvenilir bir parametre olarak öne çıkmaktadır. Bunun temel nedeni, dental gelişimin çevresel etkenlerden, özellikle beslenme durumu ve endokrin bozukluklar gibi sistemik değişkenlerden, iskeletsel gelişime kıyasla daha az etkilenmesidir.³ Bu nedenle diş yaşı, çocuklarda biyolojik olgunluğun değerlendirilmesinde önemli bir indikatör olarak kabul edilmektedir.⁴

Diş yaşı belirlemede güvenilirlikleri ve uygulanabilirlikleri açısından en yaygın kullanılan yöntemler Demirjian ve Willems yöntemleridir.⁵ Bu geleneksel yöntemler, diş gelişim evrelerinin değerlendirilmesine dayalı manuel yaklaşımlar olup, uzun yıllardır hem klinik hem de adli alanlarda kullanılmaktadır. Günümüzde ise, hesaplama gücündeki artış ve algoritmalarındaki ilerlemelere paralel olarak, diş yaşı tahmini alanında yapay zekâ destekli yöntemler ön plana çıkmaya başladığı görülmektedir.⁶

Yapay zekâ alanında özellikle öne çıkan derin öğrenme, çok katmanlı yapay sinir ağları ve benzeri algoritmalarla, ham verilerden anlamlı özellikler çıkarabilen bir makine öğrenmesi yaklaşımıdır. Bu sistemlerde yer alan nöronlar, sayısal ağırlıklarla birbirine bağlanarak verilerin işlenmesini sağlamakta ve öğrenme süreci boyunca bu ağırlıklar güncellenmektedir. Derin öğrenme modelleri genellikle, başlangıçta manuel olarak

etiketlenmiş görüntü veri kümeleriyle eğitilmekte ve zamanla örüntü tanıma kapasiteleri gelişmektedir.⁷ Bu yöntem sayesinde eksik diş, kuron morfolojisi, çürük lezyonları, periodontal problemler ve periapikal patolojiler gibi pek çok dental durum otomatik olarak analiz edilebilmekte ve teşhis süreci desteklenebilmektedir. Derin öğrenme algoritmaları, dental radyografilerin değerlendirilmesinde çeşitli çalışmalarda uygulanmış olup, bu çalışmaların büyük çoğunluğu iki boyutlu görüntüler üzerinden gerçekleştirilmektedir. Derin öğrenme yöntemleri, verinin farklı temsil seviyelerini çıkarabilme özelliği sayesinde, sınıflandırma ve tespit gibi görevlerde yüksek doğruluk oranlarıyla kullanılabilir. Bu bağlamda, diş yaşı tahmini amacıyla geliştirilen yapay zekâ uygulamaları, klasik yöntemlere alternatif olarak değerlendirilmeye başlanmıştır.^{8,9}

Derin öğrenmenin görüntü işleme alanındaki en yaygın uygulama biçimlerinden biri olan evrişimli sinir ağları, özellikle görsel verilerin analizi için geliştirilmiş özel bir mimaridir. Evrişimli sinir ağı mimarileri, görüntülerdeki kenar, köşe ve yapısal öznitelikleri algılayabilmek için konvolüsyonel çekirdekler kullanarak öznitelik haritaları oluşturur. Bu yapı sayesinde, ham görüntü verilerinden başlanarak önce basit düzeyde, ardından daha karmaşık seviyelerde özellikler çıkarabilmektedirler. Evrişimli sinir ağları, insan beyninin görsel korteksinde gerçekleşen bölgesel analiz prensiplerinden esinlenerek tasarlanmış olup, görsel tanıma görevlerinde yüksek başarı göstermektedir.^{10,}

¹¹ Dijital görüntüleme sistemlerinin yaygınlaşması ile birlikte, yapay zekâ uygulamaları radyoloji alanında önemli bir yer edinmiştir; ancak, evrişimli sinir ağlarının diş hekimliğinde kullanımı, özellikle panoramik radyografiler üzerinde sınırlı düzeyde araştırılmıştır.⁹⁻¹¹

Bu tez çalışmasının amacı, çocuklara ait panoramik radyografilerde Demirjian yöntemine göre etiketlenmiş diş gelişim evrelerini kullanarak geliştirilen derin öğrenme tabanlı bir yapay zekâ modelinin diş yaşı tahminindeki performansını değerlendirmek ve bu modelin, aynı yöntemi manuel olarak uygulayan uzman ve araştırma görevlisi ile doğruluk ve güvenilirlik açısından karşılaştırılmasını sağlamaktır.

Bu doğrultuda çalışmada aşağıdaki hipotezler test edilmiştir:

H0: Uzman diş hekimi ve araştırma görevlisi tarafından Demirjian yöntemine göre yapılan diş yaşı tahminleri ile derin öğrenme temelli yapay zekâ uygulaması tarafından yapılan tahminler arasında istatistiksel olarak anlamlı bir fark yoktur.

H1: Uzman diş hekimi ve araştırma görevlisi tarafından Demirjian yöntemine göre yapılan diş yaşı tahminleri ile derin öğrenme temelli yapay zekâ uygulaması tarafından yapılan tahminler arasında istatistiksel olarak anlamlı bir fark vardır.

2. GENEL BİLGİLER

2.1. Dişlerin Gelişimi

Diş gelişimi, embriyonik dönemde başlayan ve oral epitel ile nöral krest kökenli mezenşim arasındaki etkileşimle yönlendirilen, genetik ve çevresel faktörlerin etkisi altındaki çok aşamalı bir süreçtir. Bu süreçte, farklı embriyolojik kökenlere sahip hücre grupları dişin çeşitli bileşenlerini oluşturmaktadır; mine ektodermal epitelden, dentin, pulpa ve periodontal bağ dokuları ise nöral krest kaynaklı ektomezenşimal hücrelerden gelişmektedir.¹²

Dişin gelişim süreci, morfolojik ve histolojik olarak tanımlanmış evrelerden oluşmaktadır. Tomurcuk, takke ve çan evrelerini takiben mineralizasyon ve erüpsiyon evreleri gerçekleşmektedir. Her bir evre, hücresel farklılaşmaların ve doku organizasyonunun özgün biçimlerde ilerlediği aşamalardır.¹³

Diş gelişimi, intrauterin 6. haftada oral ektodermde meydana gelen epitel kalınlaşmasıyla başlamaktadır.¹⁴ Bu kalınlaşmalar sonucu oluşan vestibüler ve dental laminadan, sırasıyla oral vestibül ve süt dişi tomurcukları gelişmektedir. Dental lamina, her bir süt dişi için ektomezenşime doğru invajinasyon oluşturarak diş germlerinin temelini oluşturmaktadır.¹⁵⁻¹⁸ Üst ve alt çenede yer alan dental laminalarda, süt dişi tomurcuklarının gelişimini takiben, sağ ve sol süt ikinci azıların distalinde yer alan bölgelerde hücre proliferasyonu gerçekleşmektedir. Bu çoğalmalar sonucunda, daimî birinci büyük azı dişlerinin tomurcukları oluşmaya başlamaktadır. Daimî diş tomurcukları genellikle süt dişi tomurcuklarının lingual yüzeyinde, küçük azılar ise vestibül yönüne yer değiştirerek süt dişi köklerinin altında konumlanmaktadır.¹⁹

Tomurcuk evresini izleyen takke evresi, mine organının ilk kez belirginleştiği dönem olarak tanımlanmaktadır. Bu evrede epitelyal hücreler bölgesel olarak

farklılaşmakta ve yapı, kep şeklini almaktadır.^{20, 21} Mine organının merkezinde oluşan çukurluk giderek derinleşmekte ve yaklaşık intrauterin 12. haftada, iç yüzeydeki küboidal hücreler sütunsu biçime dönüşerek iç mine epitelini oluşturmaktadır. İç mine epiteli, ilerleyen aşamalarda ameloblastlara farklılaşarak mine dokusunun gelişimini başlatmaktadır.²⁰ Mine organının dış kısmında yer alan hücreler, küboidal yapılarını koruyarak dış mine epiteli şeklinde organize olmakta ve bu yapı, mine organının genel formunun korunmasına katkı sağlamaktadır. İç mine epitelinin hemen altında konumlanan yoğun mezenşimal hücre grubu ise, ilerleyen süreçte pulpa dokusunu oluşturacak olan dış papillasını meydana getirmektedir.^{20, 21}

Mine organını çevreleyen ve ilerleyen gelişim sürecinde periodontal ligament (PDL) dokusunu oluşturacak olan lifli ve kapsüler yapı, dış folikülü olarak adlandırılmaktadır. İntrauterin 14. haftada, mine organı daha karmaşık bir yapı kazanmakta ve stratum intermedium ile stellat retikulum olmak üzere iki yeni katman gelişmektedir. Stratum intermedium, ameloblastların işlevlerini sürdürebilmesi için besin taşınmasında görev almakta; stellat retikulum ise yapısal destek ve koruma sağlamaktadır. İç ve dış mine epiteli hücrelerinin sürekli büyüyerek birleştiği bölgede ise servikal halka olarak isimlendirilen yapı ortaya çıkmaktadır. Servikal halka hücreleri, ilerleyen dönemde kökün şeklini ve formunu belirleyen Hertwig epitel kök kılıfını oluşturmaktadır. Bu yapı dış kökü gelişiminde kritik bir öneme sahiptir.²⁰

Takke evresini takiben başlayan ve çan evresi olarak adlandırılan bu dönemde, hem hücresel farklılaşmalar hız kazanmaktadır hem de dışın özgün morfolojisi belirginleşmektedir. Bu aşamada, dental germin epitel kökenli hücrelerinden farklılaşan ameloblastlar mine dokusunu, iç mine epiteline komşu mezenşim kökenli hücrelerden gelişen odontoblastlar ise dentin dokusunu oluşturmaktadır. Bu hücrelerin farklılaşarak matris üretimine başlamasıyla birlikte, ilk sert doku oluşumu gerçekleşmektedir.²¹ Aynı

evrede, mine organındaki invajinasyon süreci devam etmekte ve yapı karakteristik çan şeklini almaktadır.²²

Diş gelişiminin mineralizasyon evresi, dentin ve mine dokularının hidroksiapatit kristalleriyle sertleştiği dönemdir. Bu evre, dişin fonksiyonel dayanıklılığı açısından kritik öneme sahiptir. Gelişimsel sürecin son aşaması olan sürme evresi ise dişin çene kemiği içerisinden ağız boşluğuna doğru hareketini ve fonksiyonel konumuna ulaşmasını kapsamaktadır.¹² Bu gelişimsel süreç, genetik faktörler başta olmak üzere hormonal, çevresel ve sistemik faktörlerden de etkilenmektedir.²³

2.1.1. Mine Dokusu ve Gelişimi

Diş minesi, insan vücudundaki en sert ve en yüksek derecede mineralize olmuş dokudur.²⁴ Bu yapı, altta yer alan canlı doku olan dental pulpayı ve dentini koruyucu bir bariyer işlevi görerek, fiziksel darbeler, sıcaklık değişimleri ve kimyasal etkenler gibi zararlı uyaranların pulpaya ulaşmasını engellemektedir.²⁵

Mine dokusu, embriyonik dönemde ektoderm kökenli iç mine epitelinden farklılaşan ameloblastlar tarafından sentezlenmektedir.²² Ameloblastlar, mine üretimine başladıktan sonra diş yüzeyinde tek katmanlı bir dizilim oluşturmaktadır. Mine tabakası kalınlaştıkça bu hücreler dış mine epiteline doğru yer değiştirmekte; oluşan mine miktarına bağlı olarak ameloblastlar ile odontoblastlar arasındaki mesafe artmaktadır.^{26,}
^{27 22} Mine gelişimi, organik matriksin salgılandığı sekresyon evresi ile mineral içeriğinin arttığı mineralizasyon evresi olmak üzere iki temel basamakta gerçekleşmektedir. İlk aşamada ameloblastlar tarafından salgılanan organik matriks, kısa sürede mineral kristallerinin birikimiyle sertleşmeye başlamakta ve mineralizasyon süreci başlamaktadır.^{28, 29}

2.1.2. Dentin Dokusu ve Gelişimi

Dentin, embriyonik dönemde nöral krest hücrelerinden köken alan ve mine dokusundan sonra en sert ikinci biyolojik doku olarak tanımlanmaktadır.³⁰ Dişin farklı anatomik bölgeleriyle kurduğu komşuluk ilişkileri, dentinin fonksiyonel dayanıklılığını artırmakta; aynı zamanda sinir iletimi ve beslenme süreçlerini destekleyerek biyolojik önemini ortaya koymaktadır.³⁰

Dentin oluşumu, iç mine epitelinden köken alan hücrelerin, dental papilladaki hücreleri indüklemesiyle sütunsu yapıda odontoblastların farklılaşmasıyla başlamaktadır. Odontoblastlar öncelikle predentin adı verilen mineralize olmayan organik bir matriks salgılamaktadır. Predentin yaklaşık 5 µm kalınlığa ulaştığında, matriks içerisinde hidroksiapatit kristalleri birikmeye başlamakta ve bu kristallerin birleşmesiyle mineralize dentin dokusu oluşmaktadır. Dentin üretimi ilerledikçe odontoblastlar dental papillanın merkezine doğru göç etmekte; bu süreçte bıraktıkları uzantılar dentin tübülleri içinde yer almaktadır.²⁰

2.1.3. Sement Dokusu ve Gelişimi

Sement, diş kökü ile onu çevreleyen periodontal ligament ve alveol kemiği arasında yapısal ve fonksiyonel bir bağlantı sağlayan mineralize bir dokudur.³¹⁻³⁴ Kök gelişiminin tamamlanmasının ardından, Hertwig'in epitelyal kök kılıfı parçalanmakta ve diş folikülündeki mezenşimal hücreler kök dentiniyle temas ederek sementoblastlara farklılaşmaktadır. Sementoblastlar, dentin yüzeyini tek sıralı küboidal hücreler hâlinde kaplamakta ve sementin organik matriksini sentezlemektedir. Bu matriksin içine hidroksiapatit kristallerinin birikmesiyle mineralizasyon süreci başlamaktadır.²⁰

2.1.4. Pulpa Dokusu ve Gelişimi

Pulpa, dişin en iç kısmında yer alan, bağ dokusu özellikleri taşıyan yumuşak bir doku olmaktadır. Damarlar, sinirler, lenfatikler ve çeşitli hücre gruplarını içeren bu yapı; dişin gelişimi, beslenmesi, savunması ve onarımı gibi yaşamsal işlevleri yürütmektedir. Pulpa, mine ve dentin gibi sert dokularla çevrili olmasına rağmen, canlılığını koruyan dinamik bir yapıya sahiptir.³⁵

Pulpa dokusunun embriyolojik kökeni mezenşimal hücrelere dayanmaktadır. Diş gelişiminin takke ve çan evrelerinde, dental papilla adı verilen mezenşimal hücreler hem dentini oluşturan odontoblastlara hem de pulpa dokusuna farklılaşmaktadır. Bu süreçte, odontoblastlar dental papillanın periferinde konumlanarak dentin matriksini üretirken, daha merkezi konumda kalan hücreler pulpa dokusunu oluşturmaktadır.³⁶ Kök oluşumu başladıktan sonra ise odontoblast salgılama görevini dental pulpa devam ettirmektedir.³⁷

2.1.5. Kök Gelişimi ve Biçimlenmesi

Dişin kuron kısmının oluşumunu takiben kök gelişimi başlamaktadır. Bu süreç, ileride mine ve sement dokularının birleşeceği anatomik sınır olan mine-sement birleşimine ulaşılmasıyla devam etmektedir.³⁸ İç ve dış mine epitelinin apikal yönde büyümesiyle, Hertwig'in Epitelial Kök Kılıfı (HEKK) olarak adlandırılan çift katmanlı bir epitel yapı oluşmaktadır. HEKK, kökün uzunluğunu, şeklini ve sayısını belirleyerek kök gelişimini yönlendirmektedir.^{20, 39, 40}

2.1.5. Periodontal ligament ve Gelişimi

Periodontal ligament (PDL), dişin alveolar kemiğe tutunmasını sağlayan ve çeşitli hücre gruplarını içeren dinamik bir bağ dokusudur. Yalnızca yapısal destek sunmakla kalmayıp, aynı zamanda aktif biyolojik süreçlerin sürdürüldüğü canlı bir yapı olarak işlev görmektedir.⁴¹

Periodontal ligament oluşumu, dental folikül hücrelerinin HERS ile temas etmesiyle başlamaktadır. Bu hücreler, kök ile alveolar kemik arasındaki boşluğa göç etmekte ve kolajen lifleri salgılayan sitoplazmik uzantılar geliştirmektedir. Başlangıçta düzensiz olan bu lifler, gelişimin ilerlemesiyle birlikte kalınlaşmakta ve daha organize bir yapı kazanmaktadır.^{42, 43}

2.1.6. Diş Sürmesi

Diş sürmesi, dişlerin çene içerisindeki oluşum bölgelerinden, ağız boşluğundaki fonksiyonel konumlarına doğru gerçekleştirdiği hareket olarak tanımlanmaktadır. Dişler kemik dokusu ile çevrili olduğundan, bu süreç, hassas bir şekilde düzenlenen kemik yeniden şekillenmesine bağlıdır.⁴⁴

Kuron gelişimi süresince alveolar kemik içerisinde üç boyutlu olarak konum değiştiren dental folikül, kök oluşumunun başlamasıyla birlikte aktif bir sürme mekanizmasını tetiklemektedir ve bu süreç, dişin fonksiyonel pozisyonuna doğru ilerlemesini sağlamaktadır.⁴⁵ Bu süreç, yaşam boyu süren dinamik ve fizyolojik bir süreçtir. Bu süreklilik, özellikle karşıt diş bulunmayan bireylerde klinik olarak daha belirgin bir şekilde izlenebilmektedir.⁴⁶

Diş sürmesi süreci, teorik olarak beş temel evreye ayrılmaktadır. Bu evreler, dişin oluşum bölgesinden ağız boşluğundaki fonksiyonel konumuna ulaşana dek geçirdiği biyolojik ve morfolojik değişimleri tanımlamaktadır.⁴⁷ Pre-erüptif evre, dişin gelişiminin başladığı andan kuron oluşumunun tamamlanmasına kadar sürmektedir. Bu dönemde diş çene kemiğinde sabit kalırken, kök gelişimiyle birlikte osteoklastik aktivite artarak, kemik rezorpsiyonu ve dişin oklüzal yönde hareketi başlamaktadır.⁴⁷ İntraosseöz evre, dişin çene kemiği içindeki hareketini; mukozal penetrasyon fazı ise kuronun mukozayı geçerek ağızda ilk kez görünmesini ifade etmektedir. Her iki evre de diş sürme sürecinin

önemli aşamalarını oluşturmaktadır.¹² Preoklüzal faz, dişin ağızda görünmesinden fonksiyonel temas kurmasına kadar geçen süredir ve bu süreçte diş, periodontal ligament desteğiyle oklüzal düzleme doğru hareket etmektedir.^{48, 49} Postoklüzal faz, dişin karşıt dişle temasından sonra başlamaktadır ve yaşam boyu süren adaptif mikro hareketleri içermektedir. Çiğneme kuvvetleri diş fonksiyonel stabilite kazandırırken, aynı zamanda periodontal dokular üzerinden iletilen gerilimlerle alveolar kemikte sürekli bir yeniden yapılanmayı tetiklemektedir. Aynı zamanda bu evrede oklüzal aşınmaları kompanse etmek amacıyla dişin pozisyonu sürekli olarak mikro düzeyde ayarlanmaktadır.^{45, 49}

2.2. Diş Sürme Zamanları

Dişlerin sürme zamanlarının bilinmesi; erken ya da gecikmiş sürmelerin tanınmasında, gelişimsel bozuklukların saptanmasında ve tedavi planlamalarının doğru yapılmasında klinik açıdan büyük önem taşımaktadır. Özellikle ortodontik değerlendirmelerde ve büyüme-gelişme dönemine yönelik tedavi yaklaşımlarında dişlerin sürme zamanları dikkate alınarak müdahale zamanlaması belirlenmektedir.^{2, 4}

2.2.1. Süt Dişlenme Dönemi

Süt dişlenme dönemi, oral kavitede yalnızca süt dişlerin bulunduğu, çocukluk gelişiminin erken evresini kapsayan bir dönemdir. Bu dönem, genellikle alt santral kesici dişlerin yaklaşık 6-10 aylıkken sürmesiyle başlar ve yaklaşık 24-30 ay civarında tüm süt dişlerinin sürmesiyle tamamlanır. Daha sonra daimi birinci büyük azı dişi sürene kadar latent bir süreç yaşanır. Toplamda 20 adet süt dişi çocuğun ağızda yer alır ve bu dişler daimi dişlerin sürmesine kadar ağızda kalmaktadır.⁵⁰ Süt dişlenme olarak anılan bu süreçte dişler belli bir sıraya göre ağza konumlanmaktadır. Sürme sırası genellikle öngörülebilirdir ve çoğunlukla alt çeneden başlamaktadır.⁵¹ Cinsiyetler arasında farklılık

olabileceği gibi sürme zamanlarında sapmalar da görülebilmektedir. Diş sürmesinde 12 aya kadar olan gecikmeler normal kabul edilmektedir.⁵²

Tablo 1. Maksilladaki Süt Dişlerinin Gelişim Zamanları⁵³

Diş	SDO	KGT	Sürme Zamanı	KT
Santral kesici	İU 4. ay	1,5 ay	7,5 ay	1,5 yaş
Lateral kesici	İU 4,5. ay	2,5 ay	9. ay	2. yaş
Kanin	İU 5. ay	9. ay	18. ay	3-3,5 yaş
1. Molar	İU 5. ay	6. ay	14. ay	2,5 yaş
2. Molar	İU 6. ay	11. ay	24. ay	3. yaş

*İU: İntrauterin Dönem, SDO: Sert Doku Oluşumu, KGT: Kuron Gelişiminin Tamamlanması, KT: Kök Gelişiminin Tamamlanması

Tablo 2. Mandibuladaki Süt Dişlerinin Gelişim Zamanları⁵³

Diş	SDO	KGT	Sürme Zamanı	KT
Santral kesici	İU 4,5 ay	2,5 ay	6. ay	1,5 yaş
Lateral kesici	İU 4,5 ay	3. ay	7. ay	1,5 yaş
Kanin	İU 5. ay	9. ay	16. ay	3-3,5 yaş
1. Molar	İU 5. ay	5,5 ay	12. ay	2,25 yaş
2. Molar	İU 6. ay	10. ay	20. ay	3. yaş

*İU: İntrauterin Dönem, SDO: Sert Doku Oluşumu, KGT: Kuron Gelişiminin Tamamlanması, KT: Kök Gelişiminin Tamamlanması

2.2.2. Karışık Dişlenme Dönemi

Karışık dişlenme dönemi, süt ve daimi dişlerin ağız içerisinde eş zamanlı olarak bulunduğu bir geçiş sürecidir. Bu dönem, genellikle altı yaş civarında daimi birinci büyük azı dişlerinin sürmesiyle başlamaktadır. Alt çenede daimi birinci büyük azı dişinin ardından sırasıyla orta kesici, yan kesici, kanin, birinci küçük azı, ikinci küçük azı ve son olarak ikinci büyük azı dişleri sürmektedir. Üst çenede ise birinci büyük azıdan sonra sırasıyla orta kesici, yan kesici, birinci küçük azı, ikinci küçük azı, kanin ve ikinci büyük azı dişlerinin ağızda yer aldığı gözlemlenmektedir.⁵⁴⁻⁵⁶

Bu dönem, çocuğun dentofasiyal gelişim süreci doğrultusunda üç temel evreye ayrılmaktadır.⁵⁷ 6-8,5 yaş aralığı, karışık dişlenmenin ilk evresi olarak değerlendirilmektedir. Bu dönem, daimi birinci molarların ağızda yerini almasıyla başlamaktadır ve daimi kesici dişlerin sürmesiyle sona ermektedir. Diş değişiminin en yoğun yaşandığı bu süreç, hem süt hem de daimi dişlerin ağızda birlikte bulunduğu karmaşık bir geçiş dönemidir.⁵⁷ Üst sürekli yan kesici dişlerin sürmesiyle birlikte, karışık dişlenmenin birinci dönemi sona ermektedir ve ardından ara dönem olarak adlandırılan geçici bir evre başlamaktadır. Bu dönem, alt ve üst daimi kesici dişlerin ağızdaki yerlerini almasının ardından, daimi kanin ve premolar dişlerin sürme sürecinin başlamasına kadar geçen süreyi kapsamaktadır.⁵⁸ Geç karışık dişlenme dönemi, daimi kaninler ve premolar dişlerinin ağızda yer almaya başlamasıyla karakterizedir. Süreç içerisinde süt dişlerinin tamamı yerini daimi dişlere bırakmaktadır. Dönemin sonu ise ikinci molar dişlerinin sürmesiyle belirlenmektedir. Bu dönem oklüzyonun şekillenmeye devam ettiği kritik bir safhadır.⁵⁰

Geç karışık dişlenme dönemi genellikle 10 yaş civarında başlamaktadır ve ortalama olarak 1 ila 1,5 yıl sürmektedir. Diş sürme zamanlamasının yaklaşık 1,5 yıllık

bir standart sapma aralığında seyrettiği göz önünde bulundurulmalı; dolayısıyla çocuklar arasındaki bireysel farklılıkların normal kabul edilmesi gerektiği unutulmamalıdır.⁵⁸

Tablo 3. Maksilladaki Sürekli Dişlerin Gelişim Zamanları⁵⁹

Diş	Sürme Zamanı (Yıl)
Üst Orta Kesici	7–8 yaş
Üst Yan Kesici	8–9 yaş
Üst Birinci Molar	6–7 yaş
Üst Köpek Dişi	11–12 yaş
Üst Birinci Premolar	10–11 yaş
Üst İkinci Premolar	10–12 yaş
Üst İkinci Molar	12–13 yaş
Üst Üçüncü Molar	17–21 yaş

Tablo 4. Mandibuladaki Sürekli Dişlerin Gelişim Zamanları⁵⁹

Diş	Sürme Zamanı (Yıl)
Alt Orta Kesici	6–7 yaş
Alt Yan Kesici	7–8 yaş
Alt Birinci Molar	6–7 yaş
Alt Köpek Dişi	9–10 yaş
Alt Birinci Premolar	10–12 yaş
Alt İkinci Premolar	11–12 yaş
Alt İkinci Molar	11–13 yaş
Üst Üçüncü Molar	17–21 yaş

2.2.3. Daimî Dişlenme Dönemi

Daimi dişlenme dönemi, ağızdaki son süt dişinin kaybını takiben ikinci büyük azı dişlerinin sürmesiyle birlikte başlamaktadır. Bu dönemle birlikte süt dişlenme süreci sona ermiş olmaktadır ve ağızda yalnızca daimi dişler yer almaya başlamaktadır. Daimi

dişlenme dönemi, oklüzyonun kalıcı halini kazandığı ve çiğneme fonksiyonlarının tam olarak geliştiği evredir. Bu süreç, bireyin ağız ve diş sağlığının korunması açısından dikkatle izlenmesi gereken bir gelişim aşamasıdır.⁶⁰

2.3. Yaş Tayini ve Önemi

Yaş tayini, bireylerin kronolojik yaşlarını belirlemeye yönelik çeşitli yöntemleri kapsamaktadır. Kronolojik yaş, klinik uygulamalar, eğitim sistemi ve yasal düzenlemelerde temel ölçüt olarak kullanılmaktadır; ancak bireyler arasındaki biyolojik gelişim farklılıkları nedeniyle her zaman fizyolojik ya da gelişimsel düzeyi doğru şekilde yansıtmamaktadır.^{61, 62}

Yaş tayini, kimlik tespiti, cezai sorumluluk değerlendirmesi, sosyal hizmet planlaması ve tıbbi müdahalelerin yönlendirilmesi gibi birçok alanda kritik bir rol üstlenmektedir.^{60, 63} Adli bilimlerde ise yaş tayini; reşitlik durumu, mülteci çocukların kimliklendirilmesi ve iskelet kalıntılarının incelenmesi gibi durumlarda temel bir yöntem olarak kullanılmaktadır.^{64, 65} Özellikle kimliği belirsiz ölümler ve hukuki ehliyetin değerlendirilmesi gibi adli süreçlerde, bireyin fiillerinin hukuki sonuçlarını algılama ve davranışlarını yönlendirme yeterliliğinin belirlenmesinde önemli bir yer tutmaktadır.^{66, 67}

Yaş tayini sürecinde, bireyin biyolojik yaşı; büyüme düzeyi, diş gelişim evreleri, kemikleşme süreçleri ve epifiz plaklarının kapanma durumu gibi çeşitli göstergeler üzerinden değerlendirilmektedir. Ayrıca boy-kilo oranı, sekonder cinsiyet özellikleri ve ileri yaşlarda gözlenen kemik ve diş aşınmaları da tahmin sürecine dâhil edilmektedir.⁶¹ Bu çok yönlü yaklaşım, yaş tahmininde daha isabetli sonuçlara ulaşılmasını sağlamaktadır.⁶⁸ Özellikle çocuk ve ergen bireylerde, gelişimsel farklılıklar nedeniyle bu değerlendirme titizlikle yürütülmelidir.^{64, 65}

Diş gelişimine dayalı yaş tayini, özellikle çocuk yaş gruplarında güvenilirliği yüksek bir yöntem olarak kabul edilmektedir. Diş gelişimi, genetik faktörlere daha güçlü şekilde bağlı olması ve çevresel etmenlerden daha az etkilenmesi nedeniyle, biyolojik yaş tayininde güvenilir bir gösterge olarak kabul edilmektedir. Bu özelliği sayesinde dental yaş, çocuklarda biyolojik olgunluğun değerlendirilmesinde önemli bir indikatör olarak öne çıkmaktadır.² Dolayısıyla, diş gelişim evrelerinin radyografik olarak değerlendirilmesi, bireyin biyolojik yaşının tahmin edilmesinde yaygın ve güvenilir bir yöntem olarak kullanılmaktadır.⁶⁹

2.4. Çocuklarda ve Adelösanlarda Diş Yaşı Belirleme Yöntemleri

2.4.1. Schour ve Massler Yöntemi

Diş gelişimini değerlendiren ilk sistematik yaklaşımlardan biri, 4. aydan 21 yaşa kadar olan dönemi 21 evrede tanımlamıştır; histolojik ve radyografik verilerle oluşturulan bu şematik tablolar, sınırlı ve sağlıklı birey örneklemleri ile cinsiyet farkının göz ardı edilmesi nedeniyle eleştirilmiştir.⁷⁰⁻⁷²

2.4.2. Gleiser ve Hunt Yöntemi

Gleiser ve Hunt yöntemi, mandibular ikinci moların 13 radyografik gelişim evresine odaklanarak dental olgunluğu değerlendirmeyi amaçlamış; kuren ve kök gelişimlerine sayısal değerler atayarak yaş tahmini yapılmasını sağlamıştır.⁷³ Ancak yöntemin yalnızca tek bir dişe dayanması ve popülasyon farklarını dikkate almaması gibi sınırlılıkları bulunmaktadır.⁷⁴

2.4.3. Nolla Yöntemi

Nolla yöntemi, maksilla ve mandibuladaki 7 daimi dişin radyografik gelişim evrelerini 0'dan 10'a kadar 11 aşamada tanımlayarak diş yaşının kantitatif olarak tahmin edilmesine olanak sağlamaktadır.⁷⁵ Ancak değerlendirmelerin subjektif olması ve cinsiyet

ile etnik farklılıkların dikkate alınmaması, yöntemin evrensel uygulanabilirliğini sınırlamaktadır.⁷⁶

2.4.4. Haavikko Yöntemi

Haavikko yöntemi, maksilla ve mandibuladaki 12 kalıcı dişin kuron ve kök gelişim evrelerine dayalı olarak diş yaşı tahmini yapılmasını sağlayan 12 aşamalı bir sistem sunmaktadır; her dişin gelişim durumu sayısal olarak değerlendirilip ortalaması alınarak diş yaşı belirlenmektedir.^{77, 78}

2.4.5. Moorrees, Fanning ve Hunt Yöntemi

Dişlerin mineralizasyon süreçlerine dayalı yaş tahmini yöntemleri arasında, diş gelişim evrelerini en ayrıntılı şekilde tanımlayan sistemlerden biri olarak öne çıkmaktadır. Moorrees, Fanning ve Hunt tarafından geliştirilen yöntem, kalıcı dişlerin mineralizasyon sürecine dayalı olarak 14 evrede diş gelişimini değerlendirmektedir; 6 evre kuron, 8 evre kök gelişimini kapsamaktadır. Bu sistem, panoramik radyografilerdeki diş evrelerinin yaş ortalamalarıyla karşılaştırılması yoluyla diş yaşı tahmini yapılmasını sağlamaktadır.⁷⁹

2.4.6. Anderson, Thomson ve Popovich Yöntemi

Moore ve arkadaşlarının⁷⁹ çalışmasına dayanan bu yöntem, sefalometrik görüntülerden elde edilen mineralizasyon evrelerine göre mandibular ve maksiller daimi dişlerin gelişimini değerlendirerek diş yaşı tahmini yapmaktadır; çevresel faktörlerden daha az etkilenmesi, yöntemin önemli bir avantajıdır.⁸⁰

2.4.7. Mörnstaad, Staaf ve Welande Yöntemi


Kuzey İsveç ve Finlandiya kökenli 541 çocuk üzerinde geliştirilen bu yöntem, panoramik radyografilerden elde edilen işlerin kuron uzunlukları, molar dişlerde mezyal ve distal kök uzunlukları ile apeks genişlikleri, ayrıca tek köklü dişlerin kök uzunlukları ve apeks açıklıkları gibi detaylı metrik ölçümlere dayalı olarak çoklu regresyon analizi

ile yaş tahmini yapmaktadır.⁸¹ Objektif ve ölçülebilir kriterlere dayanması, yüksek gözlemci uyumu sağlaması ve dijital analizle kolaylaştırılması yöntemin öne çıkan avantajlarındanıdır.⁸²

2.4.8. Demirjian Yöntemi

Demirjian yöntemi, diş gelişim evrelerine dayalı olarak bireylerin kronolojik yaşlarının tahmini amacıyla kullanılan en yaygın ve güvenilir diş yaşı tahmin yöntemlerinden biridir. İlk olarak 1973 yılında Demirjian, Goldstein ve Tanner tarafından geliştirilmiş ve Fransız-Kanada kökenli çocukların panoramik radyografileri üzerinden oluşturulan bir veri setine dayandırılmıştır.⁷⁴

Bu yöntem, alt çenede yer alan sol yedi daimi dişin (santral kesici diştten ikinci molar dişe kadar) mineralizasyon evrelerini değerlendirmeye sayanmaktadır. Her bir diş için belirlenen gelişim evresi, A'dan H'ye kadar harflendirilmiş sekiz farklı aşamada sınıflandırılmaktadır. Bu evreler, dişin kuron ve kök yapılarının gelişimine göre tanımlanmaktadır. İlk dört aşama kuronun gelişimine, son dört aşama ise kökün gelişimine karşılık gelmektedir. Bu sekiz gelişim evresine ek olarak, 2 ekstra evre daha eklenmiştir. Evre 0, üçüncü molar tomurcuğunun bulunmamasını ifade ederken; Evre 1, kalsifikasyon belirtisi olmadan yalnızca üçüncü molar tomurcuğunun varlığını ifade etmektedir. Her evre, ilgili dişin gelişim durumuna karşılık gelen spesifik bir skora sahiptir. Evre 0'a olgunluk skoru olarak 0, Evre 1'e ise 1 verilmiştir. A'dan H'ye kadar olan evrelere ise sırasıyla 2'den 9'a kadar olgunluk skorları atanmıştır. Her bir dişin gelişim evresine karşılık gelen puanların toplanmasıyla bireyin toplam olgunluk skoru elde edilmektedir. Bu toplam skor, cinsiyet ayrımı gözetilerek hazırlanmış özel dönüşüm tabloları yardımıyla diş yaşına çevrilmektedir.^{74, 83}



Şekil 1. Demirjian Diş Gelişim Evreleri⁸⁴

Tablo 5. Demirjian Yöntemine Göre Diş Gelişim Evreleri ve Tahmini Yaş Aralıkları⁸⁵

Evre	Gelişim Açıklaması	Tahmini Yaş Aralığı
A	Kalsifikasyon koni veya noktalar şeklindedir, birleşme yok.	2–4 yaş
B	Kalsifiye alanlar birleşmeye başlar, oklüzal yüzey şekillenmeye başlar.	3–5 yaş
C	Oklüzal yüzeyde mine formasyonu tamamlanmıştır, dentin görünür.	4–6 yaş
D	Kuron gelişimi tamamlanır, kök oluşumu başlar.	5–7 yaş
E	Kök, kuron yüksekliğinden kısa; bifurkasyon başlar.	6–9 yaş
F	Kök uzunluğu, kuron yüksekliğine eşit veya daha uzun.	9–12 yaş
G	Kök kanalları paralel, apeks kısmen açık.	11–14 yaş
H	Kök gelişimi tamamlanmış, apeks kapanmış.	13–16 yaş

Demirjian yöntemi, diş gelişiminin değerlendirilmesinde sıklıkla tercih edilen bir yöntem olup, temel olarak panoramik radyografiler üzerinden uygulanmaktadır. Bu yöntemin panoramik görüntülerle gerçekleştirilmesinin başlıca nedeni, mandibulanın sol yarısında yer alan sekiz kalıcı dişin mineralizasyon aşamalarının bütüncül olarak izlenebilmesine olanak sağlamasıdır. Panoramik radyografiler, rutin diş hekimliği uygulamalarında kolayca elde edilebildiğinden, ek radyografik maruziyet gerektirmemektedir; aynı zamanda intraoral periapikal radyografilere kıyasla daha düşük düzeyde radyasyon dozu ile geniş bir anatomik alanın görüntülenmesini mümkün kılmaktadır. Ayrıca mandibular bölgedeki distorsiyon, diğer görüntüleme yöntemlerine göre daha sınırlıdır. Mandibulanın sol tarafında meydana gelen hafif genişleme ise, yöntemin temelini oluşturan dişlerin mutlak boyutlarından ziyade gelişim evreleri ve göreceli morfolojik özelliklerine dayalı değerlendirme yaklaşımı nedeniyle, yöntem açısından klinik açıdan önemli bir sınırlılık oluşturmamaktadır. Bu yönüyle Demirjian yöntemi, hem güvenli hem de pratik bir yaş tayini aracı olarak diş gelişimi araştırmalarında yaygın biçimde kullanılmaktadır.⁷⁴

2.4.9. Willems Yöntemi

Willems yöntemi, Demirjian yönteminin modifiye edilmiş bir versiyonu olup, mandibular sol yedi daimi dişin A–H evrelerine dayalı gelişimini değerlendirerek her evreye yeni yaş puanları atayarak; cinsiyete özgü tablolar kullanılarak bireyin tahmini diş yaşı hesaplanmaktadır.^{86, 87}

2.4.10. Cameriere Yöntemi

Cameriere yöntemi, sol mandibular yedi daimi dişteki açık apekslerin radyometrik ölçümlerine dayanarak dental maturasyon skorunu hesaplamaktadır ve çoklu regresyon analiziyle yaş tahmini yapmaktadır; objektif ve tekrarlanabilir olması avantaj sağlarken,

genetik ve çevresel farklılıklar nedeniyle popülasyonlara özgü kalibrasyon gerektirmektedir.⁸⁸ Yöntem genellikle panoramik radyografiler üzerinden uygulanmaktadır.⁸⁹

2.4.11. Londra Atlas Yöntemi

Londra Atlası, intrauterin 28. haftadan 23 yaşa kadar olan bireylerdeki diş gelişim ve sürme düzeylerini 31 şematik çizimle sunan bir yöntem olup; bireyin panoramik radyografisindeki diş gelişimi, atlas çizimleriyle karşılaştırılarak diş yaşı tahmini yapılmaktadır.^{90, 91}

2.4.12. Yapay Zekâ Uygulamaları

Son yıllarda diş radyografilerine dayalı kronolojik yaş tahmini çalışmalarında geleneksel yöntemlerin yanı sıra yapay zekâ (YZ) ve özellikle derin öğrenme temelli modellerin kullanımı giderek yaygınlaşmaktadır.⁶ Bu gelişme, görüntü işleme ve veri analitiği alanındaki teknolojik ilerlemelerin adli diş hekimliği uygulamalarına entegrasyonunu beraberinde getirmiştir. Yapay zekâ tabanlı bu yaklaşımlar, özellikle panoramik radyograflar üzerinde otomatik olarak diş gelişim evrelerini değerlendirme ve yaş tahmininde bulunma potansiyeliyle dikkat çekmektedir.⁹²

Söz konusu teknolojilerin teknik alt yapısı, kullanılan algoritmalar ve karşılaştırmalı analizler bir sonraki bölümde ayrıntılı şekilde ele alınacaktır.

2.5. Yapay zekâ

Yapay zekâ (YZ), makinelerin, özellikle bilgisayar sistemlerinin, insan benzeri zekâ süreçlerini taklit etmesini amaçlayan bir bilişim alanıdır. Bu süreçler arasında öğrenme, akıl yürütme, problem çözme, algılama ve dil anlama gibi işlevler bulunmaktadır.⁹³

Yapay zekâya dair en yaygın tanımlardan biri John McCarthy tarafından 1956'daki Dartmouth Konferansı'nda ortaya konmuş ve şu şekilde ifade edilmiştir: "Yapay zekâ, akıllı makineler, özellikle akıllı bilgisayar programları yapma bilimi ve mühendisliğidir"⁹⁴

Zekâ, genel anlamda çevreye uyum sağlama, öğrenme, akıl yürütme ve yeni durumlara uygun davranışlar geliştirme kapasitesi olarak tanımlanmaktadır. Sternberg'e göre zekâ, "amaçlı uyum, yapılandırma ve çevreyi değiştirme yeteneğidir".⁹⁵ Bu bağlamda yapay zekâ, insan zekâsına özgü bilişsel yetileri makineler aracılığıyla modellemeye çalışmaktadır; ancak yapay zekânın, insan zekâsı gibi öznel bilinç, duygular ya da irade içerip içermediği hâlâ tartışmalıdır. İnsan zekâsı, biyolojik temellere dayalıdır; buna karşın yapay zekâ algoritmalarla tanımlanmaktadır ve mekanik bir yapı üzerine inşa edilmiştir. Bu nedenle bazı kuramcılar, yapay zekânın yalnızca "zekâ benzeri davranışlar" sergileyebileceğini savunmaktadır.⁹⁵

MIT Bilgisayar Bilimleri Laboratuvarı yöneticilerinden Edward Fredkin, BBC ile gerçekleştirdiği bir söyleşide şu ifadeyi kullanmıştır: "Tarihte üç büyük olay vardır. Bunlardan ilki kâinatın oluşumudur. İkincisi yaşamın başlangıcının olmasıdır. Üçüncüsü de yapay zekânın ortaya çıkışıdır." Bu söz, Fredkin'in yapay zekâyı yalnızca teknolojik bir gelişme olarak değil, evrenin ve yaşamın kökenine denk düzeyde tarihsel önemde bir kırılma noktası olarak değerlendirdiğini göstermektedir.⁹⁶

2.5.1 Yapay Zekâ Yaklaşımları

Yapay zekâ yaklaşımları, insanın bilişsel yetileri olan düşünme, öğrenme ve problem çözme gibi işlevlerin bilgisayar sistemleri tarafından yerine getirilmesini hedefleyen temel yöntemleri ifade etmektedir. Bu yaklaşımlar; uzman sistemler, bulanık mantık, genetik algoritmalar ve yapay sinir ağları gibi çeşitli paradigmalardan oluşmakta

olup, yapay zekâ sistemlerinin çevresel verilerden anlam çıkarabilmesini, yeni durumlara uyum sağlayabilmesini ve belirli görevleri bağımsız biçimde gerçekleştirebilmesini mümkün kılmaktadır.⁹³

2.5.1.1 Uzman Sistemler

Uzman sistemler, belirli bir alanda uzman kişilerin bilgi ve deneyimlerini taklit ederek karar verme süreçlerini gerçekleştirebilen yapay zekâ tabanlı bilgisayar programlarıdır. Bu sistemler, bilgi temsili ve mantıksal çıkarım yöntemleriyle çalışmaktadır.⁹⁷ Yapay zekâ, insan zekâsının genel bilişsel yetilerini taklit ederek farklı türdeki problemleri çözmeyi hedeflerken; uzman sistemler, belirli bir konuda uzmanlık gerektiren dar kapsamlı sorunlara odaklanmaktadır. Bu nedenle, uzman sistemlerde ilgili alana ait detaylı ve doğru bir bilgi tabanının oluşturulması, sistemin başarısı açısından kritik bir rol oynamaktadır.⁹⁸ Uzman sistemlerin temel amacı, özellikle uzman desteğine ulaşımın kısıtlı olduğu durumlarda karar verme süreçlerine destek sağlamaktır. Bu sistemler, belirli bir alandaki bilgiye dayalı olarak problem çözümüne katkıda bulunmakta ve kullanıcıya rehberlik etmektedir.⁹⁶

2.5.1.2 Bulanık Mantık

Bulanık mantık, klasik ikili mantığın kesinlik temelli yaklaşımına alternatif olarak geliştirilen ve belirsizlik içeren durumları modellemeye olanak tanıyan bir yöntemdir. Bu yaklaşım, özellikle yapay zekâ sistemlerinde insan benzeri esnek ve yorumlayıcı düşünme biçimlerinin simülasyonunu mümkün kılmıştır.⁹⁹ Böylece, gri alanların yoğun olduğu karmaşık sistemlerde daha uyumlu ve duyarlı çözümler üretilebilmektedir. Günlük yaşamda sıkça karşılaşılan ve doğrudan ikili biçimde ifade edilemeyen durumlar için bulanık mantık uygun bir çözüm aracı olarak öne çıkmaktadır.⁹⁶

2.5.1.3 Genetik Algoritmalar

Genetik algoritmalar, doğadaki evrimsel süreçlerden esinlenerek geliştirilen bir yöntemdir.⁹⁶ İnsanlardaki genetik mekanizmaların çalışma prensipleri bilgisayar ortamına uyarlanmakta; bu süreçte çözülmesi gereken problemler, kromozom benzeri veri yapıları üzerinde genetik süreçler taklit edilerek modellenmektedir. Algoritma, en iyi ve başarılı olanın hayatta kalması kavramını kullanan bir prensibe dayalı arama algoritmasıdır.¹⁰⁰


2.5.1.4 Yapay Sinir Ağları

Yapay sinir ağları, beyin ve sinir sistemi üzerine yapılan çalışmalar temel alınarak geliştirilen ve öğrenme, hatırlama, genelleme yapabilme gibi bilişsel süreçleri simüle eden bilgisayar tabanlı sistemlerdir. Bu ağlar, daha önce insan tarafından gerçekleştirilmiş örnek verilerden öğrenme yeteneği kazanarak, benzer durumlar karşısında öğrenilen bilgileri kullanarak uygun tepkiler üretebilme kapasitesine sahiptir.¹⁰¹ Böylece, karmaşık problemleri çözmede ve örüntü tanımda etkin bir şekilde kullanılabilmektedirler.¹⁰²

Belirli bir sistem için YSA modeli geliştirebilmek adına öncelikle ağın topolojisinin, eğitim algoritmasının ve aktivasyon fonksiyonlarının belirlenmesi gereklidir. Her YSA mimarisinin temelini oluşturan en basit işlem birimi, yapay sinir ağı hücresi olarak adlandırılmaktadır. Bu birim, biyolojik nöronların işlevlerini ve bilgi işleme süreçlerini taklit edecek şekilde tasarlanmıştır.¹⁰³

Yapay sinir ağı hücresinin yapısı; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere 5 temel birimden oluşmaktadır. Biyolojik sinir hücrelerinde yer alan dendrit, hücre gövdesi ve akson yapıları, yapay sinir ağlarında sırasıyla ağırlıklar, toplama işlemi ve aktivasyon fonksiyonu ile temsil edilmektedir. Bu benzetme, yapay sistemlerin biyolojik sinir sisteminin bilgi işleme mekanizmasını taklit

etmesine olanak sağlar.¹⁰⁴ Şekil 2.5'te, biyolojik bir sinir hücresi ile yapay sinir ağı hücresinin bir görseli sunulmuştur.



Şekil 2. Biyolojik Nöronun ve Yapay Sinir Ağı Nöronunun Karşılaştırmalı Yapısı^{105, 106}

Her bir yapay nöron, dış çevreden ya da önceki katmandaki nöronlardan iletilen giriş verilerini alarak işlemeye tabi tutmaktadır. Bu girdiler genellikle sayısal değerlerdir ve $x_1, x_2, \dots, x_n$ şeklinde ifade edilmektedir. Bu giriş verileri, yapay sinir ağının öğrenme mekanizmasını şekillendiren temel bilgi girdileridir.¹⁰⁷

Yapay bir sinir ağı hücresine iletilen her bir giriş (x_n), ilgili ağırlık katsayısı (w_n) ile çarpılarak toplama fonksiyonuna iletilmektedir. Bu işlem, hücrenin toplam net girdisini oluşturmaktadır.¹⁰⁷ Toplama fonksiyonu aracılığıyla elde edilen net giriş değeri, aktivasyon fonksiyonu tarafından işlenmektedir ve bu işlem sonucunda yapay sinir hücresinin çıktısı üretilmektedir.¹⁰⁸ Üretilen çıktı, ya doğrudan sistemin cevabı olarak kabul edilmekte ya da bir sonraki katmandaki yapay nöronlara girdi olarak iletilmektedir. Böylece, çok katmanlı yapay sinir ağlarında bilgi, giriş katmanından başlayarak çıktıya doğru aşamalı olarak işlenmiş olmaktadır. Yapay bir sinir ağı hücresinin, birden fazla giriş

verisini işleyebilme kapasitesi olsa da, bu işlemenin sonucunda yalnızca tek bir çıktı üretilmektedir.^{101, 109}

Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları, katmanlar halinde düzenlenmiş ve birbirine bağlı yapay sinir ağı hücrelerinden oluşan çok katmanlı bir bilgi işleme yapısıdır. Bu ağlar, biyolojik sinir sistemlerinden esinlenerek tasarlanmış olup, veriyi işleyip anlamlı çıktılar üretebilmek amacıyla farklı görevler üstlenen katmanlardan meydana gelmektedir. Tipik bir yapay sinir ağı üç temel katmandan oluşmaktadır: giriş katmanı, gizli katman ve çıktı katmanı.^{110, 111}

Yapay sinir ağlarında genellikle bir adet giriş ve bir adet çıktı katmanı bulunmaktadır. Bu iki temel katmanın arasında yer alan gizli katman birden fazla olabildiği gibi, ağı en kritik bileşenlerinden biridir.¹¹¹

Giriş katmanı, dış ortamdan alınan ham verileri veya özellikleri doğrudan olarak ağı ilk bilgi kaynağını oluşturmakta ve bu bilgileri bir sonraki işlem katmanına aktarmaktadır.¹¹² Gizli katman, giriş verileri üzerinde ağırlıklı bağlantılar aracılığıyla matematiksel işlemler gerçekleştirmektedir; bu sayede verilerdeki örüntüler, ilişkiler ve soyut özellikler ortaya çıkarılmaktadır.¹¹² Çıktı katmanı ise gizli katmandan gelen işlenmiş bilgilere dayanarak nihai çıktıyı üretmektedir.¹¹²

Yapay sinir ağı (YSA) modelleri genel olarak dört ana grupta sınıflandırılmaktadır: tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları. Bu sınıflandırma, ağı katman yapısı ve verinin ağ içerisindeki akış yönü dikkate alınarak yapılmaktadır.¹¹³

Yapay Sinir Ağlarında Eğitim Süreci

Yapay sinir ağı modellerinin eğitimi, insan öğrenme sürecine benzer şekilde, modele sunulan etiketli veriler aracılığıyla gerçekleştirilmektedir. Bu süreçte temel amaç, ağdaki yapay nöronlar arasındaki bağlantı ağırlıklarını optimize ederek modelin çıktıları ile gerçek değerler arasındaki farkı en aza indirmektir. Böylece sinir ağı, belirli örneklerden yola çıkarak genellemeler yapma yetisi kazanmakta ve yeni veriler üzerinde başarılı tahminlerde bulunabilmektedir.¹¹⁴

Eğitim süreci genellikle denetimli öğrenme paradigmasına dayanmaktadır.¹¹⁴ Girdi katmanına aktarılan veriler, ağ içindeki sayısal ağırlıklarla çarpılarak katmanlar boyunca işlenmektedir. Bu işlem sırasında aktivasyon fonksiyonları kullanılarak her katmanda dönüşüm gerçekleştirilmektedir. Son katmanda elde edilen tahminler, hedef çıktılarla karşılaştırılmaktadır ve aradaki fark, bir kayıp fonksiyonu yardımıyla hata olarak hesaplanmaktadır. Bu hata değeri, geri yayılım algoritması ve uygun bir optimizasyon yöntemi aracılığıyla ağırlıkların güncellenmesinde kullanılmaktadır. Böylece model, her yinelemede hata oranını düşürerek kendini iyileştirmektedir.^{110, 115}

Modelin doğru ve istikrarlı bir şekilde öğrenebilmesi, kullanılan veri kümesinin niteliğine doğrudan bağlı olmaktadır.¹¹⁶ Veri setinin yeterli büyüklükte, dengeli ve görevle uyumlu olması, öğrenme sürecinin başarısını arttırmaktadır. Öte yandan, veri setinde gereksiz ayrıntılar veya alakasız bilgiler bulunması, modelin gereğinden fazla örneğe uyum sağlamasına neden olabilmektedir. Bu durum, ağırlıkların uygun şekilde optimize edilmesini engelleyerek modelin genelleme yeteneğini zayıflatabilir ve aşırı öğrenme riskini artırabilmektedir.¹¹⁷

Eğitim süreci, önceden belirlenen tekrar sayısının tamamlanması ya da tanımlı bir hata eşiğine ulaşılması durumunda sonlandırılmaktadır. Bu noktada, yapay sinir ağının öğrenme sürecinin tamamlandığı kabul edilmektedir.¹¹⁵

2.5.2 Makine Öğrenimi

Makine öğrenimi yapay zekânın bir alt disiplini olarak, bilgisayar sistemlerine doğrudan çözüm yolları tanımlamak yerine, belirli algoritmalar aracılığıyla veri üzerinden öğrenme yetisi kazandırmayı amaçlamaktadır. Bu yaklaşım, klasik programlama yöntemlerinden farklı olarak, sistemin daha önce karşılaştığı ya da eğitildiği verilerden yola çıkarak, yeni karşılaşılan sorunlara çözüm üretebilmesini sağlamaktadır. Böylece, önceden tanımlanmış kurallar yerine, dinamik olarak öğrenilen bilgiler üzerinden karar veren esnek yapılar geliştirilmiş olmaktadır.¹¹⁸

Denetimli Öğrenme

Denetimli öğrenme yaklaşımında, modelin eğitimi için kullanılan veri kümesindeki her bir örnek, önceden tanımlanmış etiket bilgileriyle birlikte sunulmaktadır. Bu süreçte yalnızca giriş verileri değil, aynı zamanda bu verilere karşılık gelen doğru çıktı bilgileri de öğrenme aşamasına dâhil edilmektedir. Böylece model, giriş ve çıktı arasındaki ilişkileri öğrenerek, benzer örneklerle karşılaştığında genelleme yapabilme yetisi kazanmaktadır.¹¹⁵

Bu yaklaşım, sınıflandırma ve regresyon problemleri başta olmak üzere pek çok makine öğrenimi uygulamasında başarıyla kullanılmaktadır. Ancak yüksek doğrulukta bir öğrenme süreci için geniş, dengeli ve doğru etiketlenmiş bir veri kümesine ihtiyaç duyulması, bu yöntemin temel sınırlılıklarından biridir.¹¹⁹

Denetimsiz Öğrenme

Denetimsiz öğrenme, insan müdahalesine gerek duyulmaksızın, etiketlenmemiş veri kümeleri üzerinde gerçekleştirilen veri odaklı bir analiz sürecidir. Bu yöntemde, girdi verileri herhangi bir etiket içermediğinden, modelin öğrenme süreci tamamen denetimsiz biçimde ilerlemektedir. Amaç, veriler arasındaki yapısal benzerlikleri, gizli örüntüleri veya gruplamaları keşfetmektir.¹²⁰

Yarı Denetimli Öğrenme

Yarı denetimli öğrenme, etiketli ve etiketsiz verilerin birlikte kullanıldığı bir makine öğrenmesi yöntemidir. Denetimli ve denetimsiz öğrenme yaklaşımlarının bir kombinasyonu olarak kabul edilmektedir. Bu yaklaşımda, sınıf modellerinin oluşturulmasında etiketli örneklerden yararlanılırken; sınıflar arasındaki sınırların daha net belirlenebilmesi için etiketsiz verilerden faydalanılmaktadır.¹²¹

2.5.3 Derin Öğrenme

Derin öğrenme modelleri, ham verilerden başlayarak katmanlar aracılığıyla yüksek düzeyde özellikler çıkarabilen ve dış müdahaleye gerek kalmadan gerekli temsil bilgilerini kendiliğinden öğrenebilen temsili öğrenme yaklaşımları olmaktadır.¹²²

Yapay zekâ çalışmalarının ilk dönemlerinde kullanılan sığ yapılar, karmaşık veri kümeleri karşısında sınırlı öğrenme yeteneğine sahipti. Veri miktarının ve çeşitliliğinin artmasıyla, çok katmanlı derin öğrenme algoritmaları geliştirilerek daha etkili öğrenme sağlanmıştır. Bu derin yapılar, özellikle karmaşık veri örüntülerini ayırt etmede ve yüksek doğruluklu analizlerde geleneksel yöntemlerin ötesinde performans sergilemektedir.^{123,}

Derin öğrenme, çok katmanlı yapısı sayesinde, geleneksel makine öğrenmesi yöntemlerinde sıklıkla gerekli olan manuel özellik çıkarımına ihtiyaç duymamaktadır. Bu mimaride yer alan katmanlar, verileri doğrudan işleyerek öğrenme sürecinde gerekli olan özellikleri otomatik olarak çıkarabilmektedir. Böylece, ön işleme adımlarına gerek kalmadan, verinin anlamlı temsilleri ağ tarafından öğrenilmekte ve bu bilgiler modelin karar mekanizmasına entegre edilmektedir.¹²⁵

Derin öğrenmenin makine öğrenmesinden ayrıştığı temel noktalardan biri, büyük ölçekli veri kümeleriyle daha verimli çalışabilmesidir. Geleneksel makine öğrenmesi yaklaşımları, belirli bir veri hacminin ötesinde sınırlı performans artışı gösterirken; derin öğrenme algoritmaları, veri miktarı arttıkça öğrenme kapasitesini ve doğruluk oranını önemli ölçüde artırabilme potansiyeline sahip olmaktadır.¹²⁶

2.5.3.1 Derin Öğrenmede Kullanılan Yapay Sinir Ağı Modelleri

Derin öğrenmede kullanılan yapay sinir ağı (YSA) modelleri, insan beyninin bilişsel işlevlerinden ilham alınarak geliştirilmiştir. Bu modeller, öğrenme yeteneğine sahip yapıları sayesinde algılama, kontrol, analiz etme, veri depolama ve mevcut veriler üzerinden çıkarım yapabilme gibi çeşitli işlevleri yerine getirebilmektedir.¹¹³

Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (ESA), çok katmanlı ileri beslemeli mimarisi ve filtreleme temelli işlem yapısıyla öne çıkan bir yapay sinir ağı türüdür.¹²⁷ Bu mimari, özellikle görüntü tanıma, nesne tespiti, sınıflandırma gibi bilgisayarla görme problemlerini çözmek amacıyla tasarlanmış derin öğrenme mimarilerinden biridir.¹¹⁵

Memelilerin görsel korteksinde gözlemlenen hiyerarşik nöral örgütlenmeden esinlenerek geliştirilmiştir.^{128, 129} Evrişimli Sinir Ağları, yüksek boyutlu verilerden

anlamlı ve ayrıştırıcı düşük boyutlu öznitelikler elde etmeye yönelik çalışan bir mimari prensibe dayanmaktadır.¹³⁰

Çok katmanlı bir mimariye sahip olan Evrişimli Sinir Ağları, sırasıyla giriş, evrişim, aktivasyon, havuzlama, tam bağlantılı ve sınıflandırma katmanlarından oluşmaktadır.¹²⁷ Giriş katmanı, işlenmemiş verilerin yapay sinir ağına sunulduğu ilk yapısal bileşen olup, bu ham verilerin sonraki katmanlara iletilmesini sağlayarak ağın işlem sürecini başlatan temel noktayı oluşturmaktadır. Eğitimde kullanılan veri seti, ağın öğrenme başarısını ve sistem kaynaklarının kullanımını doğrudan etkilemektedir.¹³¹ Evrişim katmanı, ESA'ların temel bileşeni olup, filtrelerin giriş görüntüsü üzerinde kaydırılmasıyla öne çıkan özellikleri belirleyen ve özellik haritaları oluşturan bir yapıdır. İlk katmanlarda temel görsel öğeler algılanırken, derin katmanlarda daha karmaşık yapılar tanımlanarak verinin bilgisel açıdan yoğunlaştırılması sağlanmaktadır.¹³¹ Aktivasyon katmanı, evrişim katmanından elde edilen doğrusal çıktıları, ağın öğrenme kapasitesini artırmak ve eğitim sürecini hızlandırmak amacıyla doğrusal olmayan bir yapıya dönüştüren katmandır. Bu dönüşüm, aktivasyon katmanı aracılığıyla gerçekleştirilmektedir.¹²⁹ Havuzlama katmanının temel amacı, giriş verisinin boyutunu azaltarak hesaplama yükünü hafifletmektir. Bu işlem, tıpkı evrişim katmanında olduğu gibi belirli filtrelerin uygulanmasıyla gerçekleştirilmektedir. Havuzlama sürecinde bir miktar veri kaybı yaşansa da, bu durum ağın işlem hızını artırarak hem bellek kullanımını azaltmakta hem de daha verimli bir öğrenme süreci sağlamaktadır.¹³² Tam bağlı katman, genellikle havuzlama katmanından sonra gelmekte ve kendisinden önceki katmandaki tüm nöronlarla bağlantılı olan bir yapı olmaktadır.¹³¹ Tam bağlantılı katman, önceki katmanlardan gelen bilgileri birleştirerek nesneye ait özellikleri tanımlamakta ve sınıflandırma işlemini gerçekleştirerek nihai tahmini oluşturmaktadır.¹²⁷ Sınıflandırma katmanı ise tam bağlantılı katmandan sonra gelen ve derin öğrenme mimarilerinde

sınıflandırma işleminin gerçekleştirildiği son yapıdır. Katmanın çıkış nöronu sayısı, sınıflandırılması hedeflenen nesne sayısına karşılık gelmektedir.¹³¹ Bu katman, modelin son karar mekanizmasını oluşturarak verilerin önceden tanımlanmış kategorilere ayrılmasını sağlamaktadır.^{131, 133}

Evrişimli Sinir Ağlarının Eğitilmesi

Evrişimli Sinir Ağı modelinin eğitimi öncesinde, katmanların sayısı ve sıralaması ile filtre boyutu, sayısı ve adım uzunluğu gibi parametreler belirlenmektedir. Model, giriş verisini ileri besleme yoluyla katmanlar boyunca işleyerek çıktı üretmektedir; bu süreçte filtre ağırlıkları ile piksel değerleri çarpılarak sonraki katmana iletilmektedir.¹³¹ Eğitim sürecinde, modelin ürettiği çıktı gerçek değerle karşılaştırılarak tahmin hatası hesaplanmaktadır; bu hata geri yayılım yoluyla ağırlıklarının güncellenerek öğrenmesini sağlamaktadır. Eğitim sonrası test aşamasında yalnızca ileri yayılım uygulanmakta ve modelin başarımı hata oranları üzerinden değerlendirilmektedir.^{131, 133}

Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları, çıktıları bir sonraki adıma girdi olarak aktaran döngüsel yapıları sayesinde, zamana bağlı veriler arasındaki ilişkileri öğrenerek geçmiş bilgileri bellekte tutmaktadır ve bu sayede bağlamsal bütünlüğü yüksek, tutarlı sonuçlar üretebilmektedir.¹³⁴

Uzun Kısa Süreli Bellek Ağları

RNN mimarilerinde uzun süreli bağımlılıkların öğrenilmesinde yaşanan performans kayıplarını aşmak amacıyla geliştirilen hafıza hücreleri, bilgilerin uzun süreli saklanması ve gerektiğinde geri çağırılmasını sağlamaktadır.¹³⁵ Bu yapı, belleğin seçici şekilde güncellenmesine olanak tanıyarak hem öğrenme sürecinin etkinliğini artırmakta

hem de uzun vadeli ilişkilerin daha başarılı biçimde modellenmesini mümkün kılmaktadır.¹³⁶

Çok Katmanlı Algılayıcılar

Çok Katmanlı Algılayıcılar, doğrusal olmayan ilişkileri modelleyebilme ve karmaşık örüntüleri öğrenebilme yetenekleri sayesinde yapay sinir ağlarında yaygın olarak kullanılan temel mimarilerdendir. Giriş, gizli ve çıkış katmanlarından oluşan bu yapı, her nöronun önceki katmandan aldığı verileri ağırlıklarla işleyip aktivasyon fonksiyonları aracılığıyla dönüştürmesiyle çalışmakta; özellikle gizli katmanlardaki doğrusal olmayan fonksiyonlar, modelin öğrenme kapasitesini önemli ölçüde artırmaktadır.¹³⁷

Derin Otomatik Kodlayıcılar

Derin oto kodlayıcılar, denetimsiz öğrenme yaklaşımıyla çalışan ve giriş verisini sıkıştırarak temel özelliklerini öğrenip yeniden oluşturmaya dayanan bir yapay sinir ağı modelidir.^{138, 139} Giriş, gizli ve çıkış katmanlarından oluşan bu yapı, veriyi daha düşük boyutlarda temsil ederek en anlamlı öznitelikleri öğrenmeyi hedeflemekte ve bu yönüyle boyut indirgeme ile öznitelik çıkarımı gibi görevlerde etkili bir biçimde kullanılmaktadır.¹³⁴ Bu sayede model, gereksiz bilgi yükünden arındırılmış bir şekilde çalışarak daha verimli sonuçlar üretebilmektedir.¹⁴⁰

Sınırlı Boltzmann Makineleri

Sınırlı Boltzmann Makinesi, giriş verilerinin olasılık dağılımını öğrenebilen ve derin öğrenme mimarilerinde temel rol oynayan iki katmanlı yapay sinir ağı modelleridir. Görünür ve gizli katmanlardan oluşan bu yapıda, yalnızca katmanlar arası çift yönlü bağlantılar bulunmaktadır; bu sayede verilerin temsili özellikleri öğrenilirken aynı katmandaki birimler arasında doğrudan bağlantı kurulmamaktadır.¹³²

Derin İnanç Ağları

Derin İnanç Ağları, ardışık olarak yerleştirilmiş Sınırlı Boltzmann Makinelerinden (SBM) oluşan çok katmanlı olasılıksal grafik modellerdir. Bu yapılar, verilerin hiyerarşik temsillerini öğrenmeyi amaçlamaktadır ve her SBM katmanı, bir öncekinin çıktısını temel alarak daha soyut özellikler elde edilmesini sağlamaktadır. Genellikle denetimsiz öğrenme yöntemiyle eğitilen DİA'lar, etiketli veri gereksinimi olmaksızın karmaşık örüntülerin temsilde etkin rol oynamaktadır.^{127, 141}

Üretken Rekabetçi Ağlar

Üretken Rekabet Ağları, gerçek veriye benzer yeni örnekler üretmek amacıyla geliştirilen ve üretici ile ayırt edici olmak üzere iki bileşenin rekabetçi etkileşimine dayanan bir yapay sinir ağı mimarisidir; bu yapı, zamanla daha gerçekçi veri üretimini mümkün kılmaktadır.¹³⁷

2.5.3.2 Derin Öğrenme Tabanlı Görüntü Analiz Teknikleri ve Algoritmaları

1990 yılı öncesinde derin öğrenme tabanlı modellerin tıbbi görüntü analizinde kullanımı mümkün değilken, sonrasında geliştirilen algoritmalar bu alanda önemli ilerlemeler sağlamıştır. Bu gelişmeyle birlikte, bilgisayarlı görü uygulamalarında nesne tanıma ve yapısal analiz için üç temel görüntü işleme tekniği yaygın biçimde kullanılmaktadır.¹⁴²

Sınıflandırma

Sınıflandırma, bilgisayarlı görü uygulamalarında bir görüntüdeki yapıların ayırt edici özelliklerine göre önceden tanımlanmış kategorilere atanması işlemidir ve genellikle bir hastalığın varlığını, yokluğunu ya da türünü belirlemek amacıyla kullanılmaktadır.¹⁴³

Nesne algılama

Nesne tespiti, bir görüntü üzerinde belirli nesnelerin hem varlığını belirlemeyi hem de bu nesnelerin konumlarını kesin olarak saptamayı amaçlayan bir bilgisayarlı görüş görevidir.¹⁴⁴ Bu işlem, genellikle ilgili yapıların çevresine sınırlayıcı dikdörtgenler çizilerek gerçekleştirilmektedir.¹⁴⁵ Tıbbi görüntülemelerde, nesne tespiti; tümör, kist, lezyon ya da diş gibi anatomik yapıların otomatik olarak lokalize edilmesinde kullanılmakta ve tanı süreçlerinin hızlandırılmasına önemli katkı sağlamaktadır.^{146, 147}

Segmentasyon

Segmentasyon, bir görüntüdeki yapısal bölgelerin veya nesnelerin sınırlarının hassas bir şekilde ayrıştırılarak her pikselin ait olduğu anatomik ya da patolojik yapıya göre etiketlenmesi sürecidir.¹²⁴ Bu yöntem, sınıflandırmadan daha detaylı bir analiz sunarak, belirli bir yapının konumunu, şeklini ve boyutunu tam olarak belirlemeye olanak tanımaktadır. Tıbbi görüntülemelerde segmentasyon; organların, tümörlerin, damarların ya da dişlerin sınırlarının belirlenmesinde yaygın olarak kullanılmaktadır.¹⁴²

Nesne Tespitinde Kullanılan Derin Öğrenme Algoritmaları

Görüntü tabanlı derin öğrenme modelleri ile yapılan nesne tespiti işlemlerinde, görüntülerin farklı ölçeklerde olması model performansını olumsuz etkileyebilmektedir.^{148, 149} Bu sorunun üstesinden gelmek amacıyla, görüntü piramitleri ve bu piramitler üzerinde inşa edilen özellik piramitleri geliştirilmiştir.¹⁵⁰ Nesne tespitinde kullanılan dedektörlerin mimarisi genellikle üç ana bölümden oluşmaktadır: omurga, boyun ve baş.¹⁴⁸ Omurga, nesne tespiti sürecinde görüntüden alt ve üst düzey özelliklerin çıkarılmasını sağlayan temel bileşen olup; boyun katmanı bu özellikleri birleştirerek analiz için optimize ederken, baş bölümü modelin nihai tahminlerini üreten yapı olmaktadır. Nesne tespiti görevinde yaygın olarak kullanılan ve etkinliği literatürde

kabul gören başlıca derin öğrenme modelleri; YOLO (You Only Look Once), SSD (Single Shot Multibox Detector) ve Faster R-CNN'dir.¹⁵¹

R-CNN (Region-based Convolutional Neural Network)

R-CNN, nesne tespiti için önerilen ilk CNN tabanlı mimari olup, sınıflandırma ve konum belirleme adımlarını birleştiren dört aşamalı yapısıyla derin öğrenme tabanlı nesne algılama yöntemlerinin temelini oluşturmuştur. Ancak her bölge önerisi için CNN'in ayrı ayrı uygulanması, işlem süresini uzatmakta ve verimliliği sınırlamaktadır.^{152 131, 153 154}

Fast R-CNN

R-CNN'in işlem süresi dezavantajını gidermek amacıyla geliştirilen Fast R-CNN, tüm görüntüde tek seferde elde edilen özellik haritasını bölge önerileriyle paylaşarak nesne algılama sürecini daha hızlı ve verimli hâle getirmiştir.^{131, 155, 156}

Faster R-CNN

Faster R-CNN, R-CNN ve Fast R-CNN'in eğitim sürecini hızlandırmak amacıyla geliştirilmiş iki aşamalı bir nesne algılama mimarisidir. Bölge Öneri Ağı (RPN) ile oluşturulan bölge adayları, Fast R-CNN yapısıyla entegre edilerek işlenir; ortak evrişimli katman kullanımı sayesinde işlem süresi azaltılırken tespit doğruluğu artırılmıştır.¹⁵⁷

SSD (Single Shot Multibox Detector)

SSD, bölge önerisine ihtiyaç duymadan tek bir evrişimli sinir ağıyla hem sınıflandırma hem de konum tahmini yaparak hızlı ve gerçek zamanlı nesne tespiti sağlayan tek aşamalı bir derin öğrenme modeli olmaktadır.^{158 151}

YOLO (You Only Look Once)

Nesne tespiti alanında en yaygın kullanılan derin öğrenme modellerinden biri olan YOLO (You Only Look Once), tek bir evrişimli sinir ağı ile nesne tespitini gerçek zamanlı ve yüksek doğrulukla gerçekleştiren, sade ve hızlı bir dedektör mimarisi sunan, ESA tabanlı derin öğrenme modelidir.¹⁵⁴

YOLO'nun Gelişimi

YOLOv1 mimarisi, 24 evrişimli ve 2 tam bağlı katmandan oluşan yapıyla DarkNet omurgası üzerinde geliştirilmiş, 1×1 evrişim katmanları ile modelin verimliliği artırılmıştır. Gerçek zamanlı nesne tespiti için tasarlanan bu yapı yaklaşık 45 FPS hız sunarken, daha hızlı çalışan Fast YOLO sürümü ise 9 evrişimli katmanla 150 FPS'yi aşan performans göstermektedir.¹⁵⁴

YOLOv2, YOLOv1'in düşük duyarlılık gibi sınırlılıklarını gidermek amacıyla DarkNet-19 omurgasıyla geliştirilmiş ve doğruluk ile hız açısından performans artışı sağlamış olmaktadır.¹⁴⁵ Bunu izleyen YOLOv3 ise, DarkNet-53 tabanlı daha derin yapısıyla çok ölçekli tahmin yeteneği sunarak hem küçük hem büyük nesnelerde daha yüksek tespit doğruluğu hedeflemiştir.¹⁵⁹

YOLOv4 modeli, CSPDarknet-53 omurgası ile bilgi akışını ve parametre optimizasyonunu geliştirerek doğruluk ve verimliliği artırmayı hedeflemiştir.¹⁴⁸ 2020 yılında geliştirilen YOLOv5 ise benzer yapıyı temel alarak CSPDarknet mimarisiyle çok ölçekli özellik haritaları üretmiş, farklı donanım ihtiyaçlarına yönelik YOLOv5n, s, m, l ve x sürümleriyle esnek bir kullanım sunmuştur.¹⁶⁰

2022 yılında tanıtılan YOLOv6 modeli, RepVGG ve CSPStackRep gibi alternatif omurga yapılarıyla önceki sürümlerden ayrılarak, tek ve çok kanallı teknikleri bir arada kullanarak tespit performansını artırmayı hedeflemiştir.¹⁶¹ Aynı yıl geliştirilen YOLOv7

ise, temel mimarisini korurken aktivasyon fonksiyonları ve yapısal bileşenlerde yapılan iyileştirmelerle genel performansı yükseltmiştir.¹⁶² YOLOv7 modelinde, ağ performansını artırmak amacıyla ELAN modülü entegre edilmiş olup, YOLOv5 ile benzer model boyutuna rağmen daha yüksek doğruluk ve işlem hızı sunarak nesne tespitinde öne çıkan bir mimari haline gelmiştir.¹⁶³

YOLOv8 Mimarisinin İçeriği

2023 yılında Ultralytics tarafından geliştirilen YOLOv8, önceki sürümlerden bağımsız olarak tasarlanmış, nesne tespiti, segmentasyon, sınıflandırma ve poz tahmini gibi görevlerde yüksek doğruluk ve hız sunan, çok yönlü ve verimli bir derin öğrenme modelidir.¹⁶⁴ Farklı boyut ve en-boy oranlarına sahip nesneleri tespit edebilen bu model, denetimli öğrenme yaklaşımıyla eğitilmekte; eğitim sürecinde, kayıp fonksiyonu aracılığıyla tahmin ve gerçek değerler arasındaki fark en aza indirilerek sınıf ve konum doğruluğu artırılmaktadır. Eğitim süresi ise, kullanılan veri kümesinin büyüklüğü ve modelin hesaplama karmaşıklığına bağlı olarak değişmektedir.¹⁶⁴

YOLOv8, parametre sayısı, işlem süresi ve doğruluk düzeyi bakımından farklılık gösteren YOLOv8n, s, m, l ve x olmak üzere beş alt sürüm sunmaktadır; bu sürümler arasında YOLOv8x modeli, daha fazla evrişim katmanı ve genişletilmiş bir ağ derinliği ile en yüksek doğruluğu sunmayı hedeflerken; daha küçük modeller düşük donanımlı sistemler için optimize edilmiştir.¹⁶⁴

Modelin eğitimi, denetimli öğrenme yaklaşımı temelinde gerçekleştirilir. Bu süreçte modele etiketli görüntüler sunulur; her görüntüdeki nesneler sınıf ve konum bilgileriyle birlikte tanımlanır. Model, tahmin ettiği değerlerle gerçek etiketler arasındaki farkı kayıp fonksiyonu aracılığıyla değerlendirerek parametrelerini günceller ve doğruluğunu artırır. Eğitim süresi, kullanılan veri setinin büyüklüğü, görüntü

çözünürlüğü ve seçilen model versiyonunun hesaplama karmaşıklığına bağlı olarak değişmektedir.¹⁶⁵

2024 yılında geliştirilen YOLOv9, katmanlar arası bilgi aktarımını güçlendiren yapısal iyileştirmelerle daha az parametreyle yüksek doğruluk sunarken¹⁶⁶; YOLOv10, yeni eşleme yöntemiyle küçük ve büyük nesneleri daha hassas tespit eden, farklı sistemlere uyarlanabilir bir mimari ortaya koymuştur.¹⁶⁷ YOLOv11 ise nesne tespitine ek olarak segmentasyon, poz tahmini ve sınıflandırma gibi görevleri destekleyen çok yönlü yapısıyla, sınırlı donanımlarda dahi hızlı ve doğru sonuçlar üretebilecek şekilde optimize edilmiştir.¹⁶⁸

2.5.3.3 Derin Öğrenme Kütüphaneleri

Derin öğrenme modellerinin eğitimi, büyük veriyle çalışma ve çok katmanlı ağlar oluşturma gibi işlemleri kolaylaştıran, uzmanlarca geliştirilen yazılım kütüphaneleri aracılığıyla gerçekleştirilmekte olup; bu kütüphaneler, farklı hesaplama ihtiyaçlarına göre optimize edilmiştir.^{131, 169} PyTorch, dinamik hesaplama grafiği yapısı ve Python diliyle olan uyumlu olan bir derin öğrenme kütüphanesidir. PyTorch, farklı yazılım kütüphaneleri ile uyumlu şekilde entegre çalışabilen esnek bir derin öğrenme çerçevesidir. Gelişmiş modüler yapısı sayesinde, çeşitli sinir ağı mimarilerinin oluşturulması ve eğitilmesinde yüksek performans sunmaktadır.¹⁷⁰ TensorFlow ise Google tarafından geliştirilen ve geniş topluluk desteğiyle birlikte yüksek ölçeklenebilirlik sunan bir çerçevedir.¹⁷¹ Keras, Google tarafından geliştirilen ve Python tabanlı olan Keras; evrişimli, tekrarlayan ve hibrit sinir ağı yapılarının oluşturulmasını destekleyen, kullanım kolaylığı ve hızlı prototipleme imkânı sunan bir derin öğrenme kütüphanesidir.¹³¹ Caffé, derin öğrenme ve görüntü işleme alanlarında kullanılan açık kaynaklı bir kütüphane olup, önceden eğitilmiş modeller sunarak kullanıcıların doğrudan uygulama geliştirmesine olanak tanımaktadır.¹⁷² MXNet, Python, R, Scala, Julia ve C++

gibi birçok dili destekleyen, çok disiplinli projelerde karşılaştırmalı model geliştirmeye olanak tanıyan esnek bir derin öğrenme kütüphanesidir.^{171, 173}

2.5.4 Diş Hekimliğinde Yapay Zekâ Uygulamaları

Yapay zekâ teknolojilerindeki hızlı gelişmeler, diş hekimliğinde tanı ve tedavi süreçlerini dijitalleştirerek alana önemli dönüşümler getirmektedir. Artan işlem gücü, büyük veri analizi ve bilgiye erişim kolaylığı, yapay zekânın diş hekimliğine entegrasyonunu hızlandırmıştır. Bu nedenle diş hekimliği, yapay zekâ uygulamaları açısından gelişime açık bir alan olarak öne çıkmaktadır.¹⁷⁴ YZ uygulamaları, diş hekimliğinde tanı, tedavi planlaması ve klinik karar desteği gibi alanlarda etkin şekilde kullanılmakta; bu sayede hem daha erişilebilir sağlık hizmetleri sunulmakta hem de kişiselleştirilmiş ve önleyici yaklaşımlar desteklenmektedir.^{175, 176}

Yapay zekâ sistemleri, radyografik görüntülerde insan gözünün sınırlamalarını aşarak özellikle karmaşık anatomik bölgelerde desen tanıma ve anormallik tespitinde daha hassas ve tutarlı analizler sunmaktadır.¹⁷⁷ Panoramik radyografiler, diş hekimliğinde teşhis sürecinde en yaygın kullanılan görüntüleme yöntemlerinden biridir. Teşhiste yaygın olarak kullanılsa da görüntü çakışmaları ve klinik yorgunluk tanı hatalarına neden olabilmektedir; bu sorunları azaltmak amacıyla yapay zekâ destekli analiz sistemleri devreye girmektedir.^{11, 178, 179}

Yetişkin bireylerde tanı ve tedavi süreçlerinde elde edilen yapay zekâ temelli gelişmelerin çocuk diş hekimliğine adapte edilmesi mümkün olmakla birlikte, bu alanın kendine özgü ihtiyaçları doğrultusunda yeni uygulamaların geliştirilmesi gerekmektedir.¹⁷⁴ 2023 yılı itibarıyla yapılan yayınlar, yapay zekâ uygulamalarının pedodonti alanında giderek artan bir ilgiyle karşılandığını ortaya koymaktadır. Bu alanındaki YZ tabanlı araştırmalar; çürük tanısı, diş ayrımı, yaş tayini ve ağız sağlığı

değerlendirmesi gibi çeşitli klinik alanlara odaklanmaktadır.¹⁸⁰ Çocuk diş hekimliğinde dijital veri erişiminin artmasıyla birlikte, yapay zekâ destekli uygulamalar daha yaygın ve işlevsel hâle gelmiştir. Özellikle evrişimli sinir ağı tabanlı modeller, tanısal süreçleri hızlandırmakta ve klinik karar destek sistemleri aracılığıyla hekimlere önemli katkılar sunmaktadır. Bu durum, çocuk hastalar ve ebeveynlerin tedavi sürecine daha aktif katılım göstermesini sağlarken, genel tedavi başarısını da anlamlı şekilde artırmaktadır.¹⁸⁰

2.5.5 Yapay Zekâ Uygulamalarının Sınırlamaları

Bilgisayarla görme alanında yaygın olarak kullanılan Derin Öğrenme tabanlı yaklaşımlar, önemli avantajlar sunmalarına rağmen bazı sınırlamaları da beraberinde getirmektedir. Bu yöntemlerin başlıca kısıtlarından biri, yüksek doğrulukta performans elde edebilmek için büyük miktarda etiketli veriye duydukları ihtiyaçtır. Derin yapılar içeren modellerin sıfırdan eğitilebilmesi, genellikle çok sayıda etiketlenmiş örneğin varlığını gerektirmektedir.¹¹⁴ Özellikle tıbbi görüntüleme gibi uzmanlık gerektiren alanlarda, verilerin doğru şekilde etiketlenmesi yalnızca radyologlar gibi alan uzmanları tarafından gerçekleştirilebilmekte ve bu süreç oldukça zaman alıcı ve maliyetli olmaktadır. Etiketli veri yetersizliğinin üstesinden gelebilmek için, sınırlı etiketli veri ile geniş etiketsiz verinin birlikte kullanıldığı yarı denetimli öğrenme yaklaşımlarına başvurulmaktadır.¹⁸¹

Klinik uygulamalarda kullanılan farklı görüntüleme protokolleri nedeniyle elde edilen verilerde; çözünürlük, kontrast ve sinyal-gürültü oranı gibi teknik özelliklerdeki tutarsızlıklar, tıbbi görüntü analizinde önemli bir sınırlama teşkil etmektedir. Bununla birlikte, görüntülerin standartlaştırılmamış biçimde elde edilmesi, analiz süreçlerinde karşılaşılan başka bir temel güçlük olarak öne çıkmaktadır.¹⁸¹

Derin öğrenme modelleri, sahip oldukları yüksek parametre sayısı ve karmaşık yapıları nedeniyle ciddi düzeyde hesaplama gücü ve bellek kapasitesi gerektirmektedir.¹⁰⁴ Bu modellerin eğitimi sırasında çok sayıda parametrenin birbirine karmaşık biçimde bağlanmış olması, aşırı öğrenme riskini artırmaktadır. Bu durum, modelin eğitim verilerinde yüksek doğruluk elde etmesine karşın, yeni ve görülmemiş test verileri üzerinde düşük genelleme performansı göstermesine neden olabilmektedir.¹⁸²

Bununla beraber, klinik karar verme süreci yalnızca radyografik görüntülerin değerlendirilmesine dayanmaz; anamnez, fiziksel muayene bulguları ve laboratuvar testleri gibi diğer tanısal verilerin birlikte yorumlanmasını da kapsar. Bu bütüncül yaklaşım dikkate alındığında, mevcut yapay zekâ uygulamalarının yalnızca görüntü verilerine dayalı analizleri, klinik teşhis süreçlerinde henüz yeterli düzeye ulaşamamıştır.¹⁷⁵

Genel olarak bakıldığında, yapay zekâ tabanlı sistemler; tekrarlayan görevlerin otomatikleştirilmesi ve büyük veri setlerinin analizinde sunduğu avantajlarla klinisyenlerin iş yükünü azaltmakta ve hata oranını düşürmektedir. Ancak bu sistemlerin klinik güvenilirliği, farklı hasta grupları ve senaryolara uyarlanabilirliğinin titizlikle değerlendirilmesini gerektirmektedir. Bu bağlamda, özellikle sağlık hizmetlerine erişimin kısıtlı olduğu bölgelerde yapay zekâ tabanlı sistemlerin tarama ve erken teşhis süreçlerinde önemli katkılar sunması beklenmektedir. Bununla birlikte, bu teknolojilerin güvenilir bir şekilde uygulanabilmesi için, farklı kurumlardan elde edilen geniş ve kaliteli veri setleriyle modellerin doğruluk ve genellenebilirliği kapsamlı biçimde test edilmelidir.¹⁸³

3. GEREÇ ve YÖNTEM

3.1. Çalışma Dizaynı

Bu çalışma, retrospektif tanımlayıcı bir araştırma olarak tasarlanmıştır. Araştırmada, Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi arşivinde, çeşitli klinik amaçlarla elde edilmiş 2014–2023 yılları arasına ait panoramik radyografiler değerlendirilmiştir. Çalışmaya, 5–14 yaş aralığındaki çocuklara ait olan ve aşağıdaki kriterleri karşılayan radyografik görüntüler dahil edilmiştir:

- Görüntü artefaktı içermemesi
- Diş eksikliği veya fazlalığı bulunmaması
- Herhangi bir sendromu düşündürecek radyografik bulgunun olmaması
- Görüntü kalitesinin yeterli düzeyde olması

Uygun nitelikteki panoramik radyografiler, Planmeca Promax 2D S2 (Planmeca Oy; Helsinki, Finland) cihazı ile 66 kVp, 8 mA, 16.6 sn parametreleri kullanılarak elde edilmiştir. Bu özellikleri taşıyan panoramik radyografiler çalışmaya dahil edilmiştir. Her bir hastanın yaş ve cinsiyet bilgileri kayıt altına alınmıştır.

Çalışmada, yapay zekâ tabanlı bir yazılım olan CranioCatch programı kullanılarak, Demirjian yöntemi göre diş yaşı tahmini yapılmıştır. İlk aşamada, belirtilen yaş aralığına sahip bireylere ait panoramik radyografilerde, mandibular sol daimi yedi dişin (31–37) gelişim evreleri manuel olarak Demirjian yöntemine göre etiketlenmiş ve bu veriler CranioCatch yazılımına model eğitimi amacıyla tanımlanmıştır.

Eğitim sürecinin ardından, aynı veri havuzundan rastgele seçilen 100 panoramik radyografi, 7 yıllık mesleki deneyime sahip bir Çocuk Diş Hekimliği uzmanı, 3 yıllık mesleki deneyime sahip bir Çocuk Diş Hekimliği araştırma görevlisi (tez yürütücüsü) ve

CranioCatch yazılımı ile geliştirilen yapay zekâ tabanlı bir model tarafından ayrı ayrı değerlendirilmiştir. Her bir gözlemci tarafından mandibular sol daimi dişlerin gelişim evreleri (A–H) belirlenmiş, ardından bu evrelere karşılık gelen Demirjian skorları hesaplanmıştır. Her bir panoramik radyografi için toplam skor hesaplanmış ve ilgili cinsiyet tablosu kullanılarak diş yaşı değerine dönüştürülmüştür. Son aşamada, uzman hekim, araştırma görevlisi ve yapay zekâ yazılımının elde ettiği diş yaşı değerleri, bireylerin kronolojik yaşları ile karşılaştırılmış; yöntemler arası uyum ve doğruluk düzeyleri istatistiksel olarak analiz edilmiştir.

3.2 Etik Kurul Onayı

Bu çalışma, Recep Tayyip Erdoğan Üniversitesi Tıp Fakültesi Bilimsel Araştırmalar Etik Kurulu Yönergesi'ne uygun olarak, 26.10.2023 tarihinde gerçekleştirilen toplantıda değerlendirilmiş ve 2023/250 karar numarası ile bilimsel ve etik açıdan uygun bulunmuştur (Ek 1). Gerekli kurum izni, Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Dekanlığı'ndan alınmış olup, ilgili belgeye Ek 2'de yer verilmiştir. Ayrıca, çalışma Recep Tayyip Erdoğan Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından desteklenmiştir (Proje Kodu: TSA-2024-1626).

3.3. Veri Setinin Oluşturulması

Bu çalışmada, 2014–2023 yılları arasında Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalı'na muayene amacıyla başvuran 5–14 yaş aralığındaki çocuk hastalardan elde edilen panoramik radyografiler retrospektif olarak değerlendirilmiştir. Dahil edilmesi gereken örneklem sayısı Buderer¹⁸⁴,ın duyarlılık ve özgüllük değerlerinden örneklem hesabı için önerdiği yöntem kullanılarak hesaplandı. Hesaplama yapılırken Baydoğan¹⁸⁵,ının duyarlılık ve özgüllük değerleri baz alınmıştır. 0,759 hassasiyet, 0,95 özgüllük değerinde, 95% güven aralığında, 5% kabul

edilebilir maksimum genişlikte, 0.5 olarak ayarlanan prevelansta, duyarlılık için 562, özgüllük için 146 olmak üzere toplamda en az 708 örneklemin dahil edilmesi gerektiği hesaplanmıştır. Ancak, modelin eğitim, doğrulama ve test aşamalarında yeterli veri çeşitliliğinin sağlanması ve derin öğrenme algoritmalarının yüksek veri gereksinimi göz önünde bulundurularak, örneklem büyüklüğü mümkün olduğunca artırılmıştır. Bu doğrultuda toplam 2073 panoramik radyografi incelenmiş; dışlama kriterlerine uymayan görüntüler çalışma dışı bırakılmıştır. Sonuç olarak, çalışmaya dâhil edilme kriterlerine uygun olan 1910 panoramik radyografi üzerinde çalışılmış ve etiketleme işlemi gerçekleştirilmiştir.

3.4. Radyografik Görüntülerin Ön İşlemesi

Yapay zekâ modelinde etiketleme öncesinde, panoramik radyografiler üzerinde çeşitli ön işleme adımları uygulanmıştır. Bu süreçte görüntüler, 1280×1280 piksel boyutlarında yeniden ölçeklendirilmiş ve modelin gereksinim duyduğu formatlara dönüştürülmüştür. Görüntü kalitesini artırmak ve modelin farklı varyasyonlara karşı genelleme yeteneğini geliştirmek amacıyla, Albuementations kütüphanesi kullanılarak çeşitli veri artırma teknikleri uygulanmıştır. Uygulanan başlıca ön işleme ve artırma işlemleri; bulanıklaştırma, histogram eşitleme (CLAHE), Gauss ve ISO gürültüsü, parlaklık ve kontrast ayarlamaları, HSV renk uzayı dönüşümleri, mozaik birleştirme, keskinleştirme, sepya efekti ve kar örtüsü simülasyonudur. Bu işlemler sayesinde model, farklı ışık, kontrast ve doku koşulları altında görüntüleri daha etkili tanıyabilmiş ve daha kararlı bir öğrenme süreci gerçekleştirmiştir.

3.5. Panoramik Radyografiler Üzerinde Demirjian Yöntemine Göre Diş Gelişim Evrelerinin Eğitim Verisi Olarak Etiketlenmesi

Çalışmanın ilk aşamasında, 2014–2023 yılları arasında elde edilen ve çalışmaya dahil edilen 1910 panoramik radyografi, Demirjian yöntemine göre mandibular sol daimi yedi dişin (31–37) gelişim evrelerinin belirlenmesi amacıyla etiketlenmiştir. Etiketleme sürecinde, öncelikle alt sol mandibular çene görüntüsü bir kutu içine alınarak belirlenmiştir. Ardından, bu bölgedeki dişlerin sınırları kuron (taç) kısmından kök ucuna kadar çizilmiş ve ilgili her diş için Demirjian yöntemine göre A’dan H’ye kadar olan gelişim evresi belirlenerek sisteme tanımlanmıştır. Etiketleme işlemi, modelin eğitimi için kullanılan CranioCatch yazılımı aracılığıyla gerçekleştirilmiştir.


Etiketleme işlemleri tamamlandıktan sonra, bu veriler derin öğrenme algoritmasıyla çalışan bir yapay zekâ modelinin eğitimi için kullanılmıştır. YOLOv8x mimarisi üzerine kurulu model, etiketli panoramik görüntülerden öğrenerek diş gelişim evrelerini otomatik olarak tanımlayabilir hale gelmiştir. Eğitim sürecinde veri seti; eğitim, doğrulama ve test gruplarına ayrılmış; modelin öğrenme başarımı ve genelleme yeteneği izlenmiştir.

3.6. YOLOv8x Modeli Eğitim Aşaması

Bu çalışmada, diş gelişim evrelerinin tespiti amacıyla kullanılan yapay zekâ modeli, YOLOv8x (You Only Look Once, version 8 - extended) mimarisi üzerine inşa edilmiştir. Model eğitimi için öncelikle 2014–2023 yılları arasında elde edilen ve Demirjian yöntemine göre manuel olarak etiketlenmiş 1910 panoramik radyografi kullanılmıştır. Etiketleme sürecinde, mandibular sol daimi yedi dişin (31–37) gelişim evreleri her bir görüntüde manuel olarak işaretlenmiş ve bu işlemler sonucunda toplam 14.364 adet diş etiketlemesi elde edilmiştir.

Veri setinin %80'i eğitim, %10'u doğrulama ve %10'u test amacıyla ayrılmıştır. Bu kapsamda, eğitim aşamasında 1528 panoramik görüntü ve 11460 dış etiketlemesi, validasyon aşamasında 191 görüntü ve 1428 etiket, test aşamasında ise 191 görüntü ve 1476 etiket kullanılmıştır. Bu dağılım, modelin öğrenme sürecini optimize etmek, aşırı öğrenmeyi önlemek ve genel performansını değerlendirmek amacıyla yapılandırılmıştır.

Eğitim seti, modelin öğrenme sürecinde doğrudan kullanılan ve modelin parametrelerinin güncellendiği veri kümesidir. Doğrulama veri seti, model eğitimi sırasında doğrudan öğrenme sürecine katılmayan, ancak hiperparametre optimizasyonu ve aşırı öğrenmenin (overfitting) önlenmesi amacıyla kullanılan bağımsız bir veri kümesidir. Test seti ise, eğitim tamamlandıktan sonra modelin genel başarımını nesnel biçimde değerlendirmek amacıyla kullanılan ve daha önce modelin hiç görmediği örnekleri içeren veri grubudur.



Şekil 4. Doğrulama veri setinde yapay zekâ modelinin tahmin çıktılarından örnekler

Şekil 4'te, doğrulama veri seti üzerinde çalışan yapay zekâ modelinin oluşturduğu tahmin çıktılarından örnekler sunulmaktadır. Modelin temel amacı, panoramik radyografiler üzerinde mandibular sol daimi dişleri otomatik olarak tespit etmek ve her bir dişe ait gelişim evresini doğru şekilde sınıflandırmaktır. Etiketlenmemiş panoramik radyografiler üzerinde çalışan model, ilgili diş bölgelerini otomatik olarak işaretlemiş ve her bir bölge için gelişim evresi tahmininde bulunmuştur. Şekil 4'te yer alan kutucuklar ve üzerlerindeki sınıf etiketleri, modelin gerçekleştirdiği tahminlerin görsel temsili olarak sunulmuştur.

Bu tahminlerin elde edilebilmesi için model, öncesinde eğitim veri setiyle kapsamlı bir şekilde eğitilmiştir. Epoch, derin öğrenme modellerinin eğitiminde kullanılan bir terim olup, yalnızca eğitim veri setinin tamamının yapay sinir ağına bir kez gösterilmesini ifade etmektedir. Modelin eğitimi toplamda 800 epoch boyunca sürdürülmüştür. Eğitim süreci boyunca modelin kayıp ve doğruluk eğrileri düzenli olarak

izlenmiş; bu sayede aşırı öğrenme riski değerlendirilmiş ve gerekli durumlarda erken durdurma stratejisi göz önünde bulundurulmuştur. Model, 123. epoch'ta doğrulama veri seti üzerinde en düşük kayıp değerine ulaşarak en iyi performansını göstermiştir. Bu nedenle 123. epoch, “en iyi ağırlıklar” olarak kaydedilmiştir. Takip eden 100 epoch boyunca eğitim süreci devam ettirilmişse de bu ilave eğitim, doğrulama seti üzerindeki model başarımını anlamlı düzeyde artırmamış ve genel doğrulukta iyileşme gözlenmemiştir.

Model eğitimi sırasında kullanılan öğrenme oranı değeri 0,01 olarak belirlenmiştir. Öğrenme oranı, modelin her güncelleme adımında ağırlıklarını ne kadar değiştirdiğini belirleyen hiperparametredir. Bu çalışmada seçilen 0,01 değeri, dengeli bir öğrenme süreci sağlamak amacıyla tercih edilmiştir. Düşük öğrenme oranı daha yavaş ama daha istikrarlı bir öğrenme sağlarken, yüksek öğrenme oranı modelin daha hızlı öğrenmesini sağlar ancak dengesizliğe ve lokal minimumlara sapılma riskine yol açabilir. 0.01 öğrenme oranı sayesinde model, düzenli ve etkili bir şekilde öğrenmiş ve istenilen sonuca aşamalı olarak yaklaşabilmiştir.

Modelin geliştirilmesi ve eğitimi sürecinde; OpenCV, PyTorch, NumPy, Pandas, TorchVision, Torch, TensorBoard ve Seaborn gibi Python tabanlı kütüphaneler kullanılmıştır.

Eğitim süreci tamamlandıktan sonra model, daha önce ayrılmış test veri seti üzerinde değerlendirilmiş; kesinlik, duyarlılık ve F1 skoru gibi performans metrikleri hesaplanarak modelin genel başarımını analiz edilmiştir.

3.7. Yapay Zekâ Modelinin Doğruluk Değerlendirmesi

Yapay zekâ modelinin doğruluk ve güvenilirliğini değerlendirmek amacıyla, test veri kümesi üzerinde çeşitli sınıflandırma performans metrikleri hesaplanmıştır. Bu

çalışmada kullanılan panoramik radyografik görüntülerin %10'unu oluşturan 191 adet örnek, modelin eğitim sürecine dâhil edilmeksizin yalnızca test aşamasında kullanılmak üzere ayrılmıştır. Bu veri seti, modelin daha önce karşılaşmadığı yeni örneklerden oluşmakta olup, geliştirilen yapay zekâ algoritmasının gerçek dünya koşullarındaki genellenebilir performansını değerlendirmek amacıyla kullanılmıştır. Modelin eğitim ve doğrulama süreçleri tamamlandıktan sonra, test veri setine uygulanan tahminler ile bu görüntülere ait gerçek etiketler karşılaştırılmış; Böylece, modelin tespit ettiği gelişim evresi sınıflandırmaları üzerinden doğru pozitif (DP), yanlış pozitif (YP) ve yanlış negatif (YN) değerleri elde edilmiştir. Bu temel ölçütler aşağıda tanımlanmıştır:

- **Doğru Pozitif (DP):** Modelin, bir dişin gelişim evresini doğru şekilde tahmin ettiği durumları ifade eder.
- **Yanlış Pozitif (YP):** Modelin, gerçekte ait olmadığı halde bir gelişim evresine aitmiş gibi hatalı tahmin yaptığı durumları ifade eder.
- **Yanlış Negatif (YN):** Gerçekte gelişim evresi mevcut olmasına rağmen, modelin bu evreyi tespit edemediği durumları ifade eder.

Bu çalışmada modelin sınıflandırma başarımını daha kapsamlı şekilde değerlendirebilmek için **F1 skoru** da hesaplanmıştır. F1 skoru, modelin hem **kesinlik** hem de **duyarlılık** değerlerini dikkate alan, dengeleyici bir metriktir. Özellikle veri dengesizliğinin söz konusu olduğu durumlarda, yalnızca doğruluk oranlarına bakmak yanıltıcı olabileceğinden, F1 skoru modelin gerçekçi performansını daha doğru yansıtmaktadır.

Kesinlik (Precision): Modelin pozitif olarak tahmin ettiklerinin ne kadarının gerçekten doğru olduğunu göstermektedir. Formülü:

$$\text{Kesinlik} = \frac{TP}{TP + FP}$$

Şekil 5. Kesinlik (Precision) Formülü¹⁸⁶

Duyarlılık (Recall): Gerçekte pozitif olan örneklerin ne kadarının model tarafından doğru şekilde tahmin edildiğini göstermektedir. Formülü:

$$\text{Duyarlılık} = \frac{TP}{TP + FN}$$

Şekil 6. Duyarlılık (Recall) Formülü¹⁸⁶

Bu iki ölçütün (duyarlılık ve kesinlik) harmonik ortalaması alınarak **F1 skoru** hesaplanmaktadır. F1 skoru, hem yanlış pozitif hem de yanlış negatif durumları dikkate aldığı için, hatalı pozitif tahminleri ve kaçırılan doğru tahminleri aynı anda değerlendiren dengeli bir ölçüt olarak kabul edilir.

$$F1 = \frac{2 \cdot \text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

Şekil 7. F1 Skoru Formülü¹⁸⁶

F1 skoru, 0 ile 1 arasında bir deęer almaktadır. Skor 1'e ne kadar yakınsa, modelin hem doęru pozitif tespit oranı yüksek, hem de kaırma oranı dūřüktür. Genel olarak:

- 0,90–1,00: Mükemmel performans
- 0,80–0,89: Çok iyi
- 0,70–0,79: İyi
- 0,60–0,69: Orta-iyi
- 0,50–0,59: Orta düzey
- 0,50 altı: Zayıf performans olarak deęerlendirilmektedir.

Modelin genel sınıflandırma performansını deęerlendirmek amacıyla, bilgisayarla görü uygulamalarında yaygın olarak kullanılan **mean Average Precision (mAP)** metrięi hesaplanmıřtır. mAP, bir modelin bir nesneyi (örneğin bir diři veya diřin gelişim evresini) ne kadar doęru řekilde tespit ettięini, hem sınıflandırma hem de konum doęruluęu aısından deęerlendiren kapsamlı bir başarı ölçütüdür.

Bu metrik, modelin kesinlik ve duyarlılık deęerleri dikkate alınarak hesaplanmaktadır. Bu iki deęiřkenin birbiriyle iliřkisi, **Precision (kesinlik)–Recall (Duyarlılık) (P–R)** eęrisi aracılıęıyla görselleřtirilmektedir. Bu eęrinin altında kalan alan **Average Precision (AP)** olarak adlandırılmaktadır. Eęer birden fazla sınıf varsa, bu sınıflara ait AP deęerlerinin ortalaması alınarak **mean Average Precision (mAP)** deęeri elde edilmektedir. Böylece modelin farklı sınıflamakta ve birleşim üzerinden ortalama keřiřme (IoU) altında gösterdięi genel performans bütüncül olarak deęerlendirilmiř olmaktadır.

Bu çalışmada modelin başarımı, iki farklı mAP değeri üzerinden ifade edilmiştir:

mAP@0,5, Intersection over Union (IoU) eşiği 0,5 olarak alındığında, yani tahmin edilen nesne ile gerçek nesne en az %50 oranında örtüştüğünde, modelin ortalama başarı düzeyini göstermektedir.

mAP@0,5:0,95, IoU eşiklerinin 0,5'ten 0,95'e kadar her 0,05'lik artışla hesaplanması sonucu elde edilen ortalama değerdir. Bu değer, modelin yalnızca gevşek değil, aynı zamanda daha sıkı ve hassas konum tahmini gerektiren koşullar altında da ne kadar başarılı olduğunu yansıtır.

Değerlendirmede kullanılan **IoU**, modelin tahmin ettiği nesne konumu ile gerçek nesne konumu arasındaki örtüşme oranını ifade etmektedir. Bu oran, tahmin kutusu ile gerçek kutunun kesişiminin, bu iki kutunun birleşimine bölünmesiyle elde edilmektedir. IoU değeri 0 ile 1 arasında bir değer alır; 1'e yaklaştıkça tahminin doğruluğu artar. mAP hesaplamalarında kullanılan eşik değerleri, bu IoU oranına dayalı olarak belirlenmektedir.¹⁸⁷

3.8. Yapay Zekâ ve Gözlemciler Tarafından Gerçekleştirilen Diş Gelişimi Etiketlemeleri ve Kıyaslanması

Eğitim sürecinin tamamlanmasının ardından, modelin performansını değerlendirmek amacıyla veri setinin içinden rastgele seçilen 100 panoramik radyografi, üç farklı gözlemci tarafından bağımsız olarak etiketlenmiştir. Bu gözlemciler şunlardır: bir Çocuk Diş Hekimliği uzmanı, bir Çocuk Diş Hekimliği araştırma görevlisi (tez yürütücüsü) ve çalışmada eğitilmiş olan yapay zekâ modeli. Uzman hekimin değerlendirmeleri “altın standart” olarak kabul edilmiştir ve diğer gözlemcilerin sınıflandırmaları bu referans doğrultusunda analiz edilmiştir.

Her bir gözlemci, panoramik radyografiler üzerinde mandibulanın sol tarafındaki daimi dişler olan 31, 32, 33, 34, 35, 36 ve 37 numaralı dişleri tanımlamış; bu dişlerin çevresini işaretlemiş ve gelişim evresini Demirjian yöntemine göre belirlemiştir. Bu süreç sonucunda her bir gözlemci, her bireye ait 7 dişin gelişim evresini A'dan H'ye kadar olan kategorilerden birine atamıştır.

Yapay zekâ modeli için etiketleme süreci, eğitilen YOLOv8x tabanlı modelin her panoramik radyografi üzerinde yaptığı sınıflandırmaların çıktısı doğrultusunda gerçekleştirilmiştir. Model, her bir diş için tespit edilen bounding box bölgesi içinde en yüksek olasılığa sahip evreyi tahmin ederek sınıf ataması yapmıştır.

Elde edilen sınıflandırmalar, Çocuk Diş Hekimliği uzmanı etiketlemesiyle karşılaştırılmıştır. Her bir diş evresi için doğru pozitif (DP), yanlış pozitif (YP) ve yanlış negatif (YN) sayıları hesaplanmıştır. Bu verilerden yola çıkılarak sınıf bazında kesinlik (precision), duyarlılık (recall) ve F1 skoru gibi performans metrikleri elde edilmiştir.

3.9. Kronolojik Yaşın Hesaplanması

Bu çalışmada yer alan bireylerin kronolojik yaşları, doğum tarihleri ile panoramik radyografilerin çekim tarihleri arasındaki fark temel alınarak hesaplanmıştır. Hesaplamalar Microsoft Excel programı kullanılarak otomatik formüller aracılığıyla gerçekleştirilmiştir. Bu işlemde, röntgenin çekildiği tarih ile bireyin doğum tarihi arasındaki gün, ay ve yıl farkları dikkate alınmış ve sonuçlar ondalıklı yıl formatında ifade edilmiştir. Kronolojik yaş hesaplaması, kıyaslama amacıyla seçilen 100 panoramik radyografiye ait bireyler için yapılmış olup, bu yaşlar istatistiksel karşılaştırmalarda referans veri olarak kullanılmıştır.

3.10. Diş Yaşının Hesaplanması

Çalışmada kıyaslama amacıyla seçilen 100 panoramik radyografik görüntü, üç farklı gözlemci (uzman diş hekimi, araştırma görevlisi ve yapay zekâ modeli) tarafından, her bireyin mandibuladaki sol daimi dişlerine (31–37 numaralı dişler) ait gelişim evreleri belirlenerek etiketlenmiştir. Bu evreler, Demirjian yöntemine göre A'dan H'ye kadar sınıflandırılan gelişim basamaklarını ifade etmektedir. Etiketlenen bu gelişim evreleri, her bir diş özüğü puanlama sistemine göre, cinsiyete özgü olarak Tablo 6 ve Tablo 7'de sunulan Demirjian skor tabloları doğrultusunda puanlanmıştır.

Tablo 6. Demirjian yöntemine göre 31–37 numaralı dişler için erkek bireylerde gelişim evrelerine karşılık gelen skor değerleri⁷⁴

Gelişim Evresi	31	32	33	34	35	36	37
A	0	0	0	0	1,7	0	2,1
B	0	0	0	0	3,1	0	3,5
C	0	0	0	3,4	5,4	0	5,9
D	0	3,2	3,5	7,0	9,7	8,0	10,1
E	1,9	5,2	7,9	11,0	12,0	9,6	12,5
F	4,1	7,8	10,0	12,3	12,8	12,3	13,2
G	8,2	11,7	11,0	12,7	13,2	17,0	13,6
H	11,8	13,7	11,9	13,5	14,4	19,3	15,4

Tablo 7. Demirjian yöntemine göre 31–37 numaralı dişler için kız bireylerde gelişim evrelerine karşılık gelen skor değerleri⁷⁴

Gelişim Evresi	31	32	33	34	35	36	37
A	0	0	0	0	1,8	0	2,7
B	0	0	0	0	3,4	0	3,9
C	0	0	0	3,7	6,5	0	6,9
D	0	3,2	3,8	7,5	10,6	4,5	11,1
E	2,4	5,6	7,3	11,8	12,7	6,2	13,5
F	5,1	8,0	10,3	13,1	13,5	9,0	14,2
G	9,3	12,2	11,6	13,4	13,8	14,0	14,5
H	12,9	14,2	12,4	14,1	14,6	16,2	15,6

Toplam skor değerleri elde edildikten sonra, bu değerler bireylerin cinsiyetine göre ayrı ayrı değerlendirilmiştir. Elde edilen toplam değerler, cinsiyete özgü diş yaşı dönüşüm tablolarına aktarılmıştır. Bu dönüşüm süreci, bireyin diş yaşının belirlenmesini sağlamış ve her bir gözlemcinin tahmin ettiği gelişim evreleri üzerinden elde edilen diş yaşı değerleri ortaya konmuştur. **Tablo 8** ve **Tablo 9**, sırasıyla erkek ve kız bireyler için toplam skor değerlerinin hangi diş yaşına karşılık geldiğini göstermektedir.

Tablo 8. Demirjian yöntemine göre erkek bireylerde toplam skora karşılık gelen diş yaşı değerleri⁷⁴

Yaş	Skor	Yaş	Skor	Yaş	Skor	Yaş	Skor	Yaş	Skor
3,1	12,9	6,1	34,7	9,1	84,3	12,1	94,2	15,1	97,7
3,2	13,5	6,2	35,8	9,2	85,0	12,2	94,4	15,2	97,8
3,3	14,0	6,3	36,9	9,3	85,6	12,3	94,5	15,3	97,8
3,4	14,5	6,4	38,0	9,4	86,2	12,4	94,6	15,4	97,9
3,5	15,0	6,5	39,2	9,5	86,7	12,5	94,8	15,5	98,0
3,6	15,6	6,6	40,6	9,6	87,2	12,6	95,0	15,6	98,1
3,7	16,2	6,7	42,0	9,7	87,7	12,7	95,1	15,7	98,2
3,8	17,0	6,8	43,6	9,8	88,2	12,8	95,2	15,8	98,2
3,9	17,6	6,9	45,1	9,9	88,6	12,9	95,4	15,9	98,3
4,0	18,2	7,0	46,7	10,0	89,0	13,0	95,6	16,0	98,4
4,1	18,9	7,1	48,3	10,1	89,3	13,1	95,7		
4,2	19,7	7,2	50,0	10,2	89,7	13,2	95,8		
4,3	20,4	7,3	52,0	10,3	90,0	13,3	95,9		
4,4	21,0	7,4	54,3	10,4	90,3	13,4	96,0		
4,5	21,7	7,5	56,8	10,5	90,6	13,5	96,1		
4,6	22,4	7,6	59,6	10,6	91,0	13,6	96,2		
4,7	23,1	7,7	62,5	10,7	91,3	13,7	96,3		
4,8	23,8	7,8	66,0	10,8	91,6	13,8	96,4		
4,9	24,6	7,9	69,0	10,9	91,8	13,9	96,5		
5,0	25,4	8,0	71,6	11,0	92,0	14,0	96,6		
5,1	26,2	8,1	73,5	11,1	92,2	14,1	96,7		
5,2	27,0	8,2	75,1	11,2	92,5	14,2	96,8		
5,3	27,8	8,3	76,4	11,3	92,7	14,3	96,9		
5,4	28,6	8,4	77,7	11,4	92,9	14,4	97,0		
5,5	29,5	8,5	79,0	11,5	93,1	14,5	97,1		
5,6	30,3	8,6	80,2	11,6	93,3	14,6	97,2		
5,7	31,1	8,7	81,2	11,7	93,5	14,7	97,3		
5,8	31,8	8,8	82,0	11,8	93,7	14,8	97,4		
5,9	32,6	8,9	82,8	11,9	93,9	14,9	97,5		
6,0	33,6	9,0	83,6	12,0	94,0	15,0	97,6		

Tablo 9. Demirjian yöntemine göre kız bireylerde toplam skora karşılık gelen diş yaşı değerleri⁷⁴

Yaş	Skor	Yaş	Skor	Yaş	Skor	Yaş	Skor	Yaş	Skor
3,1	14,4	6,1	39,1	9,1	87,8	12,1	96,4	15,1	99,3
3,2	15,1	6,2	40,2	9,2	88,3	12,2	96,5	15,2	99,4
3,3	15,8	6,3	41,3	9,3	88,8	12,3	96,6	15,3	99,4
3,4	16,6	6,4	42,5	9,4	89,3	12,4	96,7	15,4	99,5
3,5	17,3	6,5	43,9	9,5	89,8	12,5	96,8	15,5	99,6
3,6	18,0	6,6	45,2	9,6	90,2	12,6	96,9	15,6	99,6
3,7	18,8	6,7	46,7	9,7	90,7	12,7	97,0	15,7	99,7
3,8	19,5	6,8	48,0	9,8	91,1	12,8	97,1	15,8	99,8
3,9	20,3	6,9	49,5	9,9	91,4	12,9	97,2	15,9	99,9
4,0	21,0	7,0	51,0	10,0	91,8	13,0	97,3	16,0	100
4,1	21,8	7,1	52,9	10,1	92,1	13,1	97,4		
4,2	22,5	7,2	55,5	10,2	92,3	13,2	97,5		
4,3	23,2	7,3	57,8	10,3	92,6	13,3	97,6		
4,4	24,0	7,4	61,0	10,4	92,9	13,4	97,7		
4,5	24,8	7,5	65,0	10,5	93,2	13,5	97,8		
4,6	25,6	7,6	68,0	10,6	93,5	13,6	98,0		
4,7	26,4	7,7	71,8	10,7	93,7	13,7	98,1		
4,8	27,2	7,8	75,0	10,8	94,0	13,8	98,2		
4,9	28,0	7,9	77,0	10,9	94,2	13,9	98,3		
5,0	28,9	8,0	78,8	11,0	94,5	14,0	98,3		
5,1	29,7	8,1	80,2	11,1	94,7	14,1	98,4		
5,2	30,5	8,2	81,2	11,2	94,9	14,2	98,5		
5,3	31,3	8,3	82,2	11,3	95,1	14,3	98,6		
5,4	32,1	8,4	83,1	11,4	95,3	14,4	98,7		
5,5	33,0	8,5	84,0	11,5	95,4	14,5	98,8		
5,6	34,0	8,6	84,8	11,6	95,6	14,6	98,9		
5,7	35,0	8,7	85,3	11,7	95,8	14,7	99,0		
5,8	36,0	8,8	86,1	11,8	96,0	14,8	99,1		
5,9	37,0	8,9	86,7	11,9	96,2	14,9	99,1		
3,1	14,4	6,1	39,1	9,1	87,8	12,1	96,4		

Bu şekilde her bir gözlemcinin etiketlemesine dayalı diş yaşı değerleri elde edilmiştir. Bu değerler, bireylerin gerçek kronolojik yaşları ile karşılaştırılarak yaş tahmin doğruluğu analiz edilmiş ve ayrıca gözlemciler arası tutarlılık değerlendirmelerine olanak sağlanmıştır.

3.11. İstatistiksel Analiz

Araştırmada elde edilen verilerin istatistiksel analizi Statistical Package for the Social Sciences (SPSS) Windows versiyon 25,0 (SPSS Inc., Chicago, IL, ABD) yazılımı kullanılarak gerçekleştirilmiştir. Tanımlayıcı istatistikler kapsamında her bir ölçüm yöntemi için ortalama, standart sapma, medyan, minimum ve maksimum değerler raporlanmıştır. Verilerin normal dağılıma uygunluğu Shapiro-Wilk testi ile değerlendirilmiştir.

Normal dağılım varsayımının karşılanmadığı durumlarda, bağımsız dört ölçüm yöntemi (kronolojik yaş, uzman hekim, araştırma görevlisi, yapay zekâ) arasındaki farklılıkların analizinde Kruskal-Wallis testi kullanılmıştır. Anlamlı fark saptanan durumlarda, farkın hangi gruplardan kaynaklandığını belirlemek amacıyla Post Hoc Bonferroni düzeltmeli ikili karşılaştırmalar yapılmıştır.

Bununla birlikte, farklı gözlemciler ve yöntemler arasında yapılan ölçümlerin tutarlılığını değerlendirmek amacıyla Sınıf İçi Korelasyon Katsayısı (Intraclass Correlation Coefficient – ICC) analizi uygulanmıştır. Analizler hem tüm katılımcılar için genel düzeyde hem de cinsiyet (kız/erkek) alt grupları için ayrı ayrı gerçekleştirilmiştir. Tüm istatistiksel testlerde anlamlılık düzeyi $p < 0,05$ olarak kabul edilmiştir.

4. BULGULAR

4.1. Yapay Zekâ Modelinin Performans Değerlendirmesi

Bu çalışmada, mandibular sol daimi dişlerin gelişim evrelerini otomatik olarak tespit etmek amacıyla derin öğrenme tabanlı bir yapay zekâ modeli geliştirilmiştir. Model, YOLOv8x (You Only Look Once, version 8 – extended) mimarisi üzerine inşa edilmiş olup, diş gelişim evrelerini sınıflandırmaya yönelik olarak eğitilmiştir. Eğitim sürecinde, 2014–2023 yılları arasında elde edilen ve Demirjian yöntemine göre manuel olarak etiketlenmiş panoramik radyografiler kullanılmıştır. Toplamda 1910 görüntüden oluşan veri setinin %80'i eğitim, %10'u doğrulama ve %10'u test amacıyla ayrılmıştır. Model, 800 epoch boyunca optimize edilmiş; en iyi doğrulama performansı 123. epoch'ta elde edilmiş ve bu nokta “en iyi ağırlıklar” olarak kaydedilmiştir.

Modelin sınıflandırma başarımı, test veri seti üzerinde F1 skoru, precision, recall ve mean Average Precision (mAP) gibi temel metriklerle değerlendirilmiştir. Test verisi çıktıları incelendiğinde; **Doğru Pozitif (TP): 1091, Yanlış Pozitif (FP): 649 ve Kaçırılan Pozitif (FN): 356** olarak tespit edilmiştir. Bu bulgular doğrultusunda modelin sınıflandırma performansı, **F1 skoru $\approx 0,5206$** olarak hesaplanmıştır. Bu skor, modelin mevcut eşik ayarlarıyla test verisinde ulaştığı fiili sınıflandırma başarısını yansıtmakta olup, genel olarak orta düzeyde bir performansa işaret etmektedir. Yani model bazı doğru tahminler üretmiş olsa da, yanlış pozitif ve kaçırılan pozitif oranları görece yüksektir. Bu nedenle, modelin geliştirilme sürecinde doğruluk (precision) ve kapsayıcılık (recall) dengesini iyileştirmeye yönelik optimizasyonlara ihtiyaç duyulduğu söylenmektedir.

Geliştirilen yapay zekâ modelinin sınıflandırma başarımı, aşağıdaki mAP değerleri doğrultusunda değerlendirilmiştir:

mAP@0,5 = 0,686: IoU eşiği 0,5 olarak kabul edildiğinde modelin ortalama sınıflandırma başarımı %68,6 olarak hesaplanmıştır. Bu metrik, daha gevşek bir eşik sunduğu için genellikle daha yüksek sonuçlar üretir. Literatürde %70'e yakın veya üzerindeki mAP@0,5 değerleri, modelin genel doğruluğunun kabul edilebilir düzeyde olduğunu göstermektedir.

mAP@0,5:0,95 = 0,64127: IoU eşik değerlerinin 0,5'ten 0,95'e kadar kademeli olarak artırılması ile elde edilen bu değer, %64,1'lik genel başarıyı yansıtmaktadır. Bu durum, modelin yalnızca gevşek değil, aynı zamanda sıkı konum doğruluğu gerektiren durumlarda da tutarlı ve dengeli sonuçlar verebildiğini göstermektedir.


Bu bağlamda, elde edilen mAP değerleri (mAP@0,5 = %68,6; mAP@0,5:0,95 = %64,1), modelin dış gelişim evrelerini farklı eşik seviyelerinde genel olarak kararlı ve kabul edilebilir düzeye yakın sınıflandırabildiğini göstermektedir.

4.1.1. Segmentasyon (Mask) Tabanlı Performans Analizi

Bu çalışmada kullanılan YOLOv8x modeli, yalnızca nesnelerin konumlarını (bounding box) değil, aynı zamanda piksel düzeyinde sınırlarını da belirleyebilen segmentasyon (mask) yeteneğine sahiptir. Segmentasyon işlemi, her bir pikselin nesneye ait olup olmadığını belirleyerek hedef nesnelerin şekilsel özelliklerini ayrıntılı biçimde ortaya koyar. Böylece model, nesneleri yalnızca konumsal olarak değil, aynı zamanda biçimsel olarak da yüksek doğrulukla sınıflandırabilmektedir. Maske uygulaması, nesneleri arka plandan ayırarak hem tespit hem de segmentasyon doğruluğunu artırmaktadır.¹⁸⁸ Aşağıda sunulan mask tabanlı grafikler, bu segmentasyon çıktılarının başarı düzeyini değerlendirmek amacıyla sunulmuştur.

Modelin sınıflandırma performansı, Precision–Recall eğrisi üzerinden de görsel olarak değerlendirilmiştir (Şekil 8). Elde edilen **mAP@0,5 = 0,686** değeri, modelin


sınıflandırma çıktılarında kesinlik ve duyarlılık dengesini genel olarak kabul edilebilir düzeyde sağladığını göstermektedir.



Şekil 8. Geliştirilen yapay zekâ modeline ait Mask Precision–Recall (Kesinlik–Duyarlılık) eğrisi


Buna ek olarak, modelin farklı confidence eşik değerlerinde nasıl bir performans gösterdiğini analiz etmek amacıyla **F1–Confidence eğrisi** kullanılmıştır. Bu eğri, güven değeri (confidence) değeri 0 ile 1 arasında değiştirildiğinde F1 skorunun nasıl etkilendiğini ortaya koymakta ve modelin hangi eşik değerinde maksimum F1 skoruna ulaştığını göstermektedir. Grafik üzerinde en yüksek ortalama F1 skoru 0,63, yaklaşık olarak confidence threshold = 0,296 seviyesinde elde edilmiştir.

Bu durum, modelin kesinlik (precision) ve duyarlılık (recall) arasındaki dengenin en optimal şekilde bu eşik değerinde sağlandığını göstermektedir. Ancak bu değer, modelin en iyi senaryo altındaki teorik performans potansiyelini temsil ederken; **0,5206'lık F1 skoru**, gerçek test çıktılarında elde edilen fiili başarı düzeyini yansıtmaktadır. Aradaki fark, modelin eşik ayarlaması yapılarak performansının daha da optimize edilebileceğini göstermektedir.




Şekil 9. Geliştirilen yapay zekâ modeline ait Mask F1–Confidence eğrisi

Modelin kesinlik başarımı, confidence skorlarına göre ayrıca analiz edilmiştir. **Şekil 10**'da görülen Precision–Confidence eğrisi, güven değeri (confidence) değeri arttıkça modelin daha seçici ve dolayısıyla daha doğru tahminlerde bulunduğunu göstermektedir.



Şekil 10. Geliştirilen yapay zekâ modeline ait Mask Precision–Confidence eğrisi

Benzer şekilde, **Şekil 11**'de yer alan Recall–Confidence eğrisi, confidence skoru yükseldikçe modelin daha az sayıda pozitif örneği yakalayabildiğini ve dolayısıyla duyarlılık (recall) değerinin düştüğünü göstermektedir. Bu eğri, modelin düşük eşik değerlerinde daha kapsayıcı; yüksek eşiklerde ise daha seçici çalıştığını ortaya koymaktadır.




Şekil 11. Geliştirilen yapay zekâ modeline ait Mask Recall–Confidence eğrisi

4.1.2. Nesne Tespiti (Box) Tabanlı Performans Analizi


YOLOv8x modeli, segmentasyon görevine ek olarak geleneksel nesne tespiti yeteneğine de sahiptir. Bu kapsamda geliştirilen model, panoramik radyografi görüntüleri üzerinde mandibular sol daimi dişleri kutucuklar (bounding box) aracılığıyla tespit etmekte ve her bir diş ile ilgili gelişim evresi ile eşleştirerek sınıflandırmaktadır. Ancak bounding box'lar, nesnenin yalnızca genel konumunu ve kapsadığı alanı belirtmekte olup, gerçek şekil veya detaylı sınırlarını tam olarak yansıtmaz. Bu nedenle, nesne tespit modellerinin başarımı; yapay zekâ tarafından tahmin edilen kutu ile gerçek kutu arasındaki örtüşme oranı gibi ölçütlerle, örneğin IoU değeri üzerinden değerlendirilmektedir. Aşağıda sunulan grafikler, modelin box düzeyinde kesinlik (precision), duyarlılık (recall) ve F1 skoru gibi temel sınıflandırma metriklerine dayalı performansını değerlendirmektedir.

Modelin nesne tespiti performansı öncelikle **Precision–Recall eğrisi** ile analiz edilmiştir (Şekil 12). Bu eğri, modelin box tabanlı sınıflandırmalarında kesinlik ve duyarlılık dengesini göstermektedir. Elde edilen mAP@0,5 değeri, modelin nesne tespit görevinde genel olarak kabul edilebilir düzeyde bir sınıflandırma gerçekleştirdiğini ortaya koymaktadır.




Şekil 12. Geliştirilen yapay zekâ modeline ait Box Precision–Recall (Kesinlik–Duyarlılık) eğrisi

Buna ek olarak, **Şekil 13**'te yer alan Box F1–Confidence eğrisi, modelin farklı güven değeri (confidence) eşik değerlerinde ulaştığı F1 skorlarını göstermektedir. Grafik üzerinde en yüksek ortalama F1 skoru yaklaşık 0,29 confidence eşik seviyesinde elde edilmiştir. Bu eğri, modelin karar eşliğinin ayarlanmasına yönelik değerlendirmelerde önemli bir referans oluşturmaktadır.




Şekil 13. Geliştirilen yapay zekâ modeline ait Box F1–Confidence eğrisi

Box Precision–Confidence eğrisi (Şekil 14), confidence değeri yükseldikçe modelin daha isabetli tahminlerde bulunduğunu; **Box Recall–Confidence eğrisi** (Şekil 15) ise yüksek eşiklerde pozitif örnekleri kaçırma olasılığının arttığını göstermektedir. Bu iki grafik birlikte değerlendirildiğinde, modelin yüksek güven değerlerinde daha seçici, düşük güven değerlerinde ise daha kapsayıcı çalıştığı görülmektedir.



Şekil 14. Geliştirilen yapay zekâ modeline ait Box Precision–Confidence eğrisi




Şekil 15. Geliştirilen yapay zekâ modeline ait Box Recall–Confidence eğrisi

Tüm bu grafiksel analizler ışığında, YOLOv8x mimarisine sahip yapay zekâ modelinin hem nesne tespiti (box) hem de segmentasyon (mask) görevlerinde genel olarak dengeli ve istikrarlı bir performans sergilediği gözlemlenmiştir.


4.1.3. Karışıklık Matrisi

Modelin sınıflandırma performansını değerlendirmek amacıyla, tahmin edilen etiketlerle gerçek etiketler arasındaki tutarlılığı gösteren karışıklık matrisi kullanılmıştır. Bu matris, her bir sınıfın ne sıklıkla doğru tahmin edildiğini ve hangi sınıflarla karıştırıldığını görsel olarak ortaya koymaktadır. Matrisin diyagonal çizgisi üzerinde yer alan koyu renkli hücreler doğru sınıflandırmaları, diyagonal dışındaki yoğunluklar ise modelin hata yaptığı sınıfları temsil etmektedir.



Şekil 16. Modelin sınıflandırma başarısına ait Karışıklık Matrisi


Şekil 16’da görüldüğü üzere, diyagonal üzerindeki yüksek yoğunluk, modelin birçok sınıfı doğru bir şekilde tahmin ettiğini göstermektedir. Ancak bazı sınıflarda gözlemlenen diyagonal dışı yoğunluklar, bu sınıfların birbirine karıştırılma potansiyelini ortaya koymaktadır.



Şekil 17. Modelin sınıflandırma başarısına ait Normalized Karışıklık Matrisi

Şekil 17’de sunulan normalize edilmiş versiyon ise her bir sınıf için doğru sınıflandırma oranlarını 0 ile 1 arasında standartlaştırarak göstermektedir. Bu sayede, sınıf bazlı başarı düzeyleri daha net bir şekilde karşılaştırılabilmekte ve modelin hangi sınıflarda daha başarılı olduğu oran bazında değerlendirilebilmektedir.

4.1.4. Eğitim Süreci ve Kayıp Fonksiyonları (Loss ve Metrikler)



Şekil 18. YOLOv8x modelinin eğitim sürecine ait kayıp ve başarı metriklerinin epoch bazında ilerleyişi

Eğitim sürecinde epoch sayısı arttıkça, modelin öğrenme kapasitesinin artması beklenir. Bu doğrultuda, kayıp fonksiyonlarının (loss) giderek azalması ve performans metriklerinin (örneğin precision, recall, mAP) yükselmesi, başarılı bir öğrenme sürecinin göstergesidir. Özellikle hem eğitim hem de doğrulama verisinde gözlenen bu düşüş, modelin hem öğrenme hem de genelleme yeteneğinin geliştiğini göstermektedir.

Ancak doğrulama kaybının eğitim kaybına kıyasla yükselmeye başlaması, modelin eğitim verisine aşırı uyum sağladığını (overfitting) gösterebilir. Bu durumda model, eğitim setini ezberleyip genel örüntüleri öğrenemez. Tersine, hem eğitim hem de doğrulama kayıplarının yüksek seyretmesi veya azalmaması ise, modelin yeterli öğrenme gerçekleştirmediğini (underfitting) ve yapısal olarak geliştirilmeye açık olduğunu işaret eder.

Şekil 20’de yer alan grafiklerde modelin eğitim sürecine ait çeşitli kayıp fonksiyonları (box, seg, cls, dfl) ve başarı metriklerinin (precision, recall, mAP) epoch

ilerleyişine göre değişimi sunulmaktadır. Eğitim kayıplarının genel olarak düzenli şekilde azalması, modelin öğrenme sürecinin başarılı olduğunu göstermektedir. Doğrulama kayıplarında yer yer artış eğilimleri gözlemlenmekle birlikte, modelin genel başarımları – özellikle precision, recall ve mAP değerlerinin – 0,7 civarında sabitlenmesi, öğrenilen parametrelerin sınıflandırma görevlerinde kararlı sonuçlar verdiğini ortaya koymaktadır. Bu durum, modelin segmentasyon ve nesne tespiti görevlerinde kabul edilebilir düzeyde bir doğruluk sergilediğini göstermektedir.

4.2. Gözlemciler Arası Gelişim Evresi Kıyaslaması

Bu bölümde, geliştirilen yapay zekâ modelinin sınıflandırma performansı, iki farklı insan gözlemci ile karşılaştırılarak değerlendirilmiştir. Karşılaştırma sürecinde, modelin etiketlemeleri sırasıyla uzman diş hekimi (altın standart) ve araştırma görevlisi tarafından yapılan referans etiketlemelerle kıyaslanmıştır. Her iki değerlendirme grubunda da, mandibular sol daimi dişlere ait gelişim evreleri temel alınarak, Doğru Pozitif (DP), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) sayıları hesaplanmış; bu değerler üzerinden precision (kesinlik), recall (duyarlılık) ve F1 skoru gibi performans metrikleri belirlenmiştir.

Bu kapsamda amaç, yapay zekâ modelinin hem uzman düzeyindeki bir hekime hem de bir araştırma görevlisine göre ne ölçüde doğru sınıflandırma yapabildiğini ortaya koymaktır. Böylece, modelin farklı düzeydeki insan gözlemciler karşısındaki tutarlılığı değerlendirilebilmiş ve klinik/pratik uygulanabilirliği hakkında çıkarımlarda bulunulmuştur.

4.2.1. Yapay Zekâ – Uzman Hekim Karşılaştırması

Bu alt bölümde, yapay zekâ modeli tarafından otomatik olarak etiketlenen gelişim evreleri ile altın standart olarak kabul edilen uzman diş hekiminin referans etiketlemeleri

karşılaştırılmıştır. Her bir sınıf için Doğru Pozitif (TP), Yanlış Pozitif (FP) ve Yanlış Negatif (YN) değerleri hesaplanarak, bu veriler üzerinden precision (kesinlik), recall (duyarlılık) ve F1 skoru gibi sınıflandırma performans ölçütleri elde edilmiştir.

Yapılan analiz sonucunda genel başarı metrikleri şu şekilde hesaplanmıştır:

- Toplam Doğru Pozitif (DP): 4
- Toplam Yanlış Pozitif (YP): 765
- Toplam Yanlış Negatif (YN): 705
- Precision (Kesinlik): 0,0052
- Recall (Duyarlılık): 0,0056
- F1 Skoru: 0,0054

Bu sonuçlar, yapay zekâ modelinin uzman hekimin etiketlemeleriyle kıyaslandığında son derece düşük düzeyde bir sınıflandırma performansı sergilediğini ortaya koymaktadır. Modelin özellikle yüksek sayıda yanlış pozitif üretmesi, gerçek sınıfları ayırt etmedeki başarısızlığını ve sınıflandırma hassasiyetinin oldukça zayıf olduğunu göstermektedir.

Sınıf bazlı analizler, yalnızca birkaç gelişim evresinde kısıtlı sayıda doğru eşleşme elde edilebildiğini ortaya koymuştur. Özellikle 31-F evresinde, TP: 3 ve F1 skoru: 0,0896 ile diğer sınıflara göre görece daha yüksek bir başarı elde edilmiştir. Bunun dışında kalan sınıfların tamamına yakınında F1 skoru 0,0000 düzeyindedir.

Bu bulgular, yapay zekâ modelinin gelişim evrelerini uzman hekimin etiketlemeleriyle uyumlu şekilde tanımlama konusunda yetersiz kaldığını ve bu haliyle klinik doğruluk düzeyinden oldukça uzak olduğunu göstermektedir.

4.2.2. Yapay Zekâ – Araştırma Görevlisi Karşılaştırması

Bu alt bölümde, yapay zekâ modeli tarafından tahmin edilen gelişim evreleri ile araştırma görevlisi tarafından yapılan referans etiketlemeler karşılaştırılmıştır. Her bir sınıf için Doğru Pozitif (TP), Yanlış Pozitif (FP) ve Yanlış Negatif (YN) değerleri belirlenmiş ve buna dayanarak precision (kesinlik), recall (duyarlılık) ve F1 skoru gibi sınıflandırma metrikleri hesaplanmıştır.

Genel sonuçlar şu şekildedir:

- Toplam Doğru Pozitif (TP): 12
- Toplam Yanlış Pozitif (FP): 757
- Toplam Yanlış Negatif (YN): 696
- Precision (Kesinlik): 0,0156
- Recall (Duyarlılık): 0,0169
- F1 Skoru: 0,0162

Bu bulgular, yapay zekâ modelinin araştırma görevlisinin etiketlemeleriyle karşılaştırıldığında sınıflandırma performansının oldukça düşük düzeyde kaldığını göstermektedir. Model, yüksek oranda yanlış sınıf tahmininde bulunmuş ve gerçek pozitif örnekleri doğru bir şekilde tespit etmekte yetersiz kalmıştır.


Sınıf düzeyinde yapılan analizler, yalnızca birkaç gelişim evresinde sınırlı sayıda doğru tahmin yapılabildiğini ortaya koymuştur. Özellikle 31-F evresinde, TP: 8 ve F1 skoru: 0,2388 ile diğer evrelere kıyasla daha yüksek bir başarı gözlemlenmiştir. Bunun dışında kalan hemen tüm evrelerde F1 skorunun 0.0000 düzeyinde kalması, modelin genel ayırt ediciliğinin oldukça zayıf olduğunu göstermektedir.

4.2.3. Gözlemciler Arası Kıyaslama ve Model Performansının Değerlendirilmesi

Yapay zekâ modelinin sınıflandırma performansı, hem uzman dış hekiminin hem de araştırma görevlisinin referans etiketlemeleri ile karşılaştırılarak analiz edilmiştir. Tablo 10’da, iki farklı gözlemci ile yapılan karşılaştırmalara ait temel sınıflandırma metrikleri özetlenmiştir. Burada sunulan karşılaştırmalı veriler, yalnızca yapay zekâ modelinin insan gözlemcilerin referans etiketlerine ne ölçüde uyum sağladığını göstermektedir. DP, YP ve YN değerleri; yapay zekâ tarafından yapılan tahminlerin, ilgili gözlemcinin (uzman hekim ya da araştırma görevlisi) etiketleriyle kaç kez doğru eşleştiğini (veya eşleşemediğini) ifade etmektedir. Dolayısıyla, bu değerler gözlemcilerin bağımsız olarak kaç örnek sınıflandırdığına dair bilgi sunmamaktadır; yalnızca model ile gözlemciler arasındaki eşleşme düzeyini ortaya koymaktadır.

Tablo 10. AI–Uzman Hekim ve AI– Araştırma Görevlisi Karşılaştırmasına Ait Precision, Recall ve F1 Skorları

Karşılaştırma	DP	YP	YN	Precision	Recall	F1 Skoru
AI – Uzman Hekim	4	765	705	0,0052	0,0056	0,0054
AI – Araştırma Görevlisi	12	757	696	0,0156	0,0169	0,0162



Şekil 19. AI-Uzman Hekim ve AI-Araştırma Görevlisi karşılaştırmasında temel sınıflandırma metrikleri

Şekil 19’da yer alan grafikte, yapay zekâ modelinin sınıflandırma metrikleri hem uzman dış hekimi hem de araştırma görevlisi ile karşılaştırmalı olarak sunulmuştur. Grafik üzerine eklenen açıklama ile, modelin araştırma görevlisine göre daha yüksek precision, recall ve F1 skoru elde ettiği açıkça vurgulanmıştır.

Bu karşılaştırma sonucunda şu bulgular öne çıkmaktadır:

- Yapay zekâ modeli, her iki gözlemciye göre de düşük performans sergilemiştir. Precision, recall ve F1 skoru değerleri %2'nin altında kalmıştır.
- Araştırma görevlisi ile yapılan karşılaştırmada, modelin daha fazla doğru pozitif (TP = 12) tespit ettiği ve daha yüksek F1 skoru elde ettiği görülmektedir. Bu durum, modelin araştırma görevlisinin etiketlemelerine daha yakın sonuçlar verdiğini göstermektedir.

- Uzman hekime göre yapılan karşılaştırmada modelin yalnızca 4 doğru eşleşme yapabildiği ve precision–recall dengesinin son derece düşük olduğu görülmektedir. Bu, modelin uzman hekim düzeyindeki etiketleme kalitesine uzak olduğunu göstermektedir.
- Özellikle 31-F evresi, her iki karşılaştırmada da görece en başarılı sınıf olmuş; bu evrede hem DP sayısı artmış hem de diğer sınıflara göre F1 skoru anlamlı düzeye ulaşmıştır (AI–Uzman Hekim için: 0,0896, AI–Araştırma Görevlisi için: 0,2388).

4.3. Diş Yaşı Tahminlerinin İstatistiksel Olarak Karşılaştırılması

Bu çalışmada, toplam 99 adet panoramik röntgen görüntüsü değerlendirmeye alınmıştır. Başlangıçta 100 röntgen planlanmış olmasına rağmen, yapay zekâ modeli bir görüntüde 32 numaralı dişi etiketleyemediğinden dolayı bu röntgen analiz dışı bırakılmış ve kıyaslamaya dahil edilen görüntü sayısı 99 olarak sınırlandırılmıştır.

Değerlendirmeye alınan bu 99 röntgenin 58’i erkek bireylere, 41’i ise kız bireylere aittir. Cinsiyet dağılımı incelendiğinde, örneklemin %58.6’sının erkeklerden, %41.4’ünün ise kızlardan oluştuğu görülmektedir (Tablo 11). Bu dağılım, çalışmanın diş yaşı tahminindeki cinsiyet farklarının değerlendirilmesine olanak sağlamaktadır.

Tablo 11. Çalışmaya Dahil Edilen Katılımcıların Cinsiyete Göre Dağılımı

Cinsiyet	Sayı	Yüzde (%)
Erkek	58	58,6
Kız	41	41,4
Toplam	99	100,0

Katılımcıların kronolojik yaşı ile üç farklı gözlemci tarafından tahmin edilen diş yaşlarına ilişkin tanımlayıcı istatistikler Tablo 12’de sunulmuştur.

Tablo 12. Kronolojik Yaş ve Diş Yaş Tahminlerine Ait Tanımlayıcı İstatistikler

Yöntem	M. (Min–Maks)	Ort±S.s
Kronolojik yaş	7,01 (4,99–13,9)	7,39±1,56
Uzman hekim	7,2 (4,2–12,5)	7,47±1,61
Araştırma görevlisi	7,6 (4,6–12,5)	7,87±1,45
Yapay zekâ	7,7 (5–12,4)	7,86±1,14

(M.: Medyan, Ort: Ortalama, S.s: Standart sapma)

Araştırmada dört farklı ölçüm yöntemi arasında yaş ölçümleri açısından istatistiksel olarak anlamlı bir farklılık olup olmadığı, verilerin normal dağılım varsayımını karşılamaması nedeniyle **Kruskal-Wallis testi** ile analiz edilmiştir. Bu parametrik olmayan yöntem, gruplar arasındaki sıra ortalamalarının karşılaştırılmasına dayalıdır. Analiz sonucunda, dört ölçüm yöntemi arasında istatistiksel olarak anlamlı düzeyde fark olduğu belirlenmiştir ($H = 18,251$; $p < 0,001$). Bu bulgu, farklı yöntemlerin diş yaşı tahminlerinde sistematik farklılıklar oluşturduğunu göstermektedir.

Tablo 13’te, katılımcıların kronolojik yaşları ile üç farklı değerlendirme yöntemi tarafından hesaplanan diş yaşlarına ait tanımlayıcı ve ilişkisel istatistiksel bulgular sunulmuştur. Kronolojik yaşı ortalama değeri $7,39 \pm 1,56$ yıl olarak hesaplanmıştır. Altın standart olarak kabul edilen uzman hekimin değerlendirmelerinde bu değer $7,47 \pm 1,61$ yıl olup, kronolojik yaşa en yakın sonucu vermektedir. Araştırma görevlisi tarafından yapılan diş yaşı tahminlerinin ortalaması $7,87 \pm 1,45$ yıl, yapay zekâ modeline ait ortalama ise $7,86 \pm 1,14$ yıl olarak bulunmuştur. Bu sonuçlar, hem araştırma görevlisinin

hem de yapay zekâ modelinin diş yaşını, kronolojik yaştan sistematik olarak daha yüksek tahmin etme eğiliminde olduğunu göstermektedir.

Ayrıca, Kruskal-Wallis testi kapsamında hesaplanan sıra ortalamaları incelendiğinde; kronolojik yaş için 168,25, altın standart için 180,70, araştırma görevlisi için 218,87 ve yapay zekâ için 226,18 olarak belirlenmiştir. Sıra ortalaması değerlerinin bu şekilde farklılaşması, yapay zekâ ve araştırma görevlisinin tahmin ettiği yaşların, uzman hekim ve kronolojik yaşa göre daha yüksek değerlere sahip olduğunu açıkça ortaya koymaktadır. En düşük sıra ortalamasına sahip olan kronolojik yaş grubu, gerçek yaş dağılımının referansını oluştururken; en yüksek sırayı yapay zekânın alması, bu yöntemin daha ileri düzeyde dental olgunluk tahmini eğilimi taşıdığını göstermektedir.

Bu kapsamda elde edilen bulgular, diş yaşı tahmininde kullanılan yöntemlerin kendi içinde sistematik farklılıklar barındırdığını ve bu farklılıkların istatistiksel olarak anlamlı olduğunu ortaya koymaktadır. Bu nedenle, post hoc analizler ile farklılığın hangi gruplar arasında ortaya çıktığının belirlenmesi gerekmektedir.

Tablo 13. Kronolojik ve Diş Yaşı Tahminlerine Ait İstatistiksel Karşılaştırma Sonuçları

Yöntem	M. (Min–Maks.)	Ort±S.s	Sıra Ortalaması
Kronolojik yaş	7,01 (4,99–13,9)	7,39±1,56	168,25
Uzman hekim	7,2 (4,2–12,5)	7,47±1,61	180,70
Araştırma görevlisi	7,6 (4,6–12,5)	7,87±1,45	218,87
Yapay zekâ	7,7 (5–12,4)	7,86±1,14	226,18

Kruskal-Wallis testi sonucu: $H = 18,251$; $p < 0,001$

Post Hoc Bonferroni analizine ilişkin bulgular Tablo 14’te sunulmaktadır. Bu tabloya göre, hem araştırma görevlisi hem de yapay zekâ tarafından yapılan yaş

tahminleri, kronolojik yaşa kıyasla istatistiksel olarak anlamlı düzeyde daha yüksek bulunmuştur ($p<0,05$). Ayrıca, yapay zekâ ve uzman hekim ölçümleri arasında da anlamlı bir fark saptanmış; yapay zekâ tahminlerinin, uzman hekimin değerlendirmelerine kıyasla daha yüksek yaşlar verdiği görülmüştür ($p=0,031$). Öte yandan, kronolojik yaş ile uzman hekim, uzman hekim ile araştırma görevlisi ve araştırma görevlisi ile yapay zekâ ölçümleri arasında istatistiksel olarak anlamlı bir fark bulunmamıştır. Bu bulgu, söz konusu ölçümlerin birbirine yakın sonuçlar ürettiğini ve bu gruplar arasındaki farkların anlamlı düzeyde olmadığını göstermektedir.

Tablo 14. Post Hoc Bonferroni analizi sonuçları

	Test İstatistiği	p
Kronolojik yaş - Uzman hekim	-12,449	1,000
Kronolojik yaş – Araştırma görevlisi	-50,626	0,011*
Kronolojik yaş - Yapay zekâ	-57,934	0,002*
Uzman hekim – Araştırma görevlisi	-38,177	0,113
Uzman hekim - Yapay zekâ	-45,485	0,031*
Araştırma görevlisi -Yapay zekâ	-7,308	1,000

* $p<0,05$

Cinsiyet gruplarına göre farklı ölçüm yöntemlerinden elde edilen yaş değerlerinin istatistiksel olarak anlamlı farklılık gösterip göstermediği, normal dağılım varsayımı sağlanmadığı için Kruskal-Wallis testi ile değerlendirilmiştir. Test sonuçları Tablo 15’de sunulmaktadır.

Kız katılımcılar için yapılan analizde, dört ölçüm yöntemi arasında istatistiksel olarak anlamlı bir fark saptanmamıştır. Bu sonuç, kızlarda kronolojik yaş, uzman hekim, araştırma görevlisi ve yapay zekâ yöntemleriyle elde edilen yaş tahminlerinin benzer düzeylerde olduğunu göstermektedir.

Erkek katılımcılar için yapılan analizde ise ölçüm yöntemleri arasında istatistiksel olarak anlamlı bir fark olduğu belirlenmiştir (Test istatistiği = 15,941, p = 0,001). Erkek grubunda ölçümler arasında gözlenen bu farkın yönünü ve hangi gruplar arasında anlamlı olduğunu belirlemek amacıyla Post Hoc Bonferroni testi uygulanmıştır (bkz. Tablo 16).

Genel olarak değerlendirildiğinde, kızlarda tüm yöntemler arasında benzer sonuçlar elde edilirken, erkeklerde araştırma görevlisi ve yapay zekâ yöntemleri kronolojik yaşa göre anlamlı düzeyde daha yüksek yaş değerleri üretmiştir. Bu durum, yapay zekâ modelinin erkek bireylerde geleneksel yaş tahmin yöntemlerine kıyasla daha yüksek sonuçlar ürettiğini göstermektedir.

Tablo 15. Cinsiyete göre farklı gözlemciler tarafından yapılan yaş tahminlerinin karşılaştırılması

	Yöntem	M. (Min-Maks.)	Ort±S.s	Sıra ortalaması	Test istatistiği	p
Kız	Kronolojik yaş	6,84 (5,01-13,9)	7,47±1,73	74,02	3,650	0,302
	Uzman hekim	7,2 (4,2-12,5)	7,41±1,54	77,01		
	Araştırma görevlisi	7,4 (4,6-12,5)	7,72±1,48	88,72		
	Yapay zekâ	7,3 (5,6-12,4)	7,77±1,33	90,24		

Tablo 15. Devamı

	Yöntem	M. (Min-Maks.)	Ort±S.s	Sıra ortalaması	Test istatistiği	p
Erkek	Kronolojik yaş	7,03 (4,99-11,68)	7,32±1,45	93,98	15,941	0,001*
	Uzman hekim	7,3 (4,3-11,7)	7,52±1,68	104,94		
	Araştırma görevlisi	7,7 (4,8-11,8)	7,98±1,44	130,76		
	Yapay zekâ	7,7 (5-10,3)	7,93±0,99	136,32		

Erkek katılımcılara ait yaş tahminleri arasında yapılan Post Hoc Bonferroni analizine ilişkin bulgular Tablo 16’da sunulmaktadır. Analiz sonuçlarına göre, hem araştırma görevlisi ($p=0,019$) hem de yapay zekâ yöntemi ($p=0,004$) ile elde edilen değerlerin, kronolojik yaş tahminlerine kıyasla istatistiksel olarak anlamlı düzeyde daha yüksek olduğu belirlenmiştir. Bu bulgular, erkek katılımcılarda araştırma görevlisi ve yapay zekâ tarafından yapılan yaş tahminlerinin kronolojik yaştan anlamlı düzeyde daha yüksek olduğunu; diğer gözlemciler arasında ise ölçümlerin benzer düzeyde gerçekleştiğini göstermektedir.

Tablo 16. Cinsiyeti erkek olan katılımcılara göre Post Hoc Bonferroni analizi sonuçları

	Test İstatistiği	p
Kronolojik yaş- Uzman hekim	-10,957	1,000
Kronolojik yaş- Araştırma görevlisi	-36,776	0,019*
Kronolojik yaş-Yapay zekâ	-42,336	0,004*
Uzman hekim - Araştırma görevlisi	-25,819	0,229
Uzman hekim -Yapay zekâ	-31,379	0,071
Araştırma görevlisi - Yapay zekâ	-5,560	1,000

Ölçümler arasındaki tutarlılığı değerlendirmek amacıyla Intraclass Correlation Coefficient (ICC) analizi gerçekleştirilmiştir. Tablo 17’de sunulan analiz sonuçlarına göre, kronolojik yaş, uzman hekim, araştırma görevlisi ve yapay zekâ tahminleri arasında oldukça yüksek düzeyde bir uyum olduğu belirlenmiştir. Elde edilen ICC değeri 0,927 olup, bu değer %95 güven aralığında 0,901 ile 0,948 arasında bulunmuştur.

Aynı zamanda, F testi sonucuna göre ($F = 13,730$, $p = 0,000$) bu ICC değeri istatistiksel olarak anlamlıdır ($p < 0,05$). Bu bulgular, çalışmada kullanılan tüm gözlemciler arasında yaş tahmini bakımından iç tutarlılık bulunduğunu göstermektedir.

Tablo 17. Ölçümlerin sınıf içi korelasyon katsayısı (ICC) sonuçları

ICC	%95 Güven aralığı		F Testi			
	Alt sınır	Üst sınır	F	Sd1	Sd2	p
0,927	0,901	0,948	13,730	98	294	0,000*

* $p < 0,05$, ICC: Intraclass Correlation Coefficient, Sd: Serbestlik derecesi

Cinsiyete göre ölçümler arasındaki tutarlılık, Intraclass Correlation Coefficient (ICC) analizi ile değerlendirilmiştir. Tablo 18’de sunulan sonuçlara göre, kadın katılımcılar için ICC değeri 0.906 olarak hesaplanmış olup, %95 güven aralığı 0.848 ile 0.945 arasında yer almaktadır. Erkek katılımcılarda ise ICC değeri 0.945 olarak bulunmuş ve güven aralığı 0.917 ile 0.965 olarak belirlenmiştir.

Her iki cinsiyet grubunda da ICC değerlerinin 0.90’ın üzerinde olması, ölçümler arasında yüksek düzeyde bir tutarlılık bulunduğunu göstermektedir. Ayrıca, F testi sonuçları hem kadınlar ($F = 10.602$, $p = 0.000$) hem de erkekler ($F = 18.149$, $p = 0.000$) için istatistiksel olarak anlamlı bulunmuştur ($p < 0.05$).

Ancak bu yüksek düzeydeki tutarlılık, tüm gözlemcilerin doğru tahminler yaptığı anlamına gelmemektedir. Nitekim, bazı gözlemciler tarafından yapılan yaş tahminlerinin sistematik olarak daha yüksek olduğu gözlemlenmiştir. Dolayısıyla ICC analizinin ölçümler arasındaki görece uyumu gösterdiği, ancak mutlak doğruluk hakkında doğrudan bilgi vermemektedir.

Tablo 18. Ölçümlerin cinsiyete göre sınıf içi korelasyon katsayısı (ICC) sonuçları

		%95 Güven aralığı		F Testi			
Cinsiyet	ICC	Alt sınır	Üst sınır	F	Sd1	Sd2	p
Kadın	0,906	0,848	0,945	10,602	40	120	0,000*
Erkek	0,945	0,917	0,965	18,149	57	171	0,000*

* $p < 0,05$, ICC: Sınıf içi korelasyon katsayıları (Intraclass Correlation Coefficient), Sd: Serbestlik derecesi

5.TARTIŞMA

Çalışma sonuçlarımız doğrultusunda, Demirjian yöntemine dayalı geliştirilen yapay zekâ modeli, diş yaşı tahmininde genel olarak uzman ve araştırma görevlisine kıyasla daha yüksek değerler üretti; özellikle erkek bireylerde bu fark istatistiksel olarak anlamlı bulundu. Buna rağmen, tüm gözlemciler arasında yüksek düzeyde uyum saptandı. Bu bulgular doğrultusunda, H_0 hipotezi reddedildi, H_1 hipotezi kabul edildi. Elde edilen sonuçlar, derin öğrenme temelli yapay zekâ modellerinin diş yaşı tahmininde destekleyici bir araç olarak kullanılabileceğini; ancak model doğruluğunun artırılması ve sınıf bazlı başarıların iyileştirilmesi amacıyla daha kapsamlı çalışmalara ihtiyaç duyulduğunu göstermektedir.

Diş yaşı, dişlerin sürme zamanları ve gelişim evrelerine dayalı olarak bireyin biyolojik olgunluğunu değerlendirmeye olanak tanıyan güvenilir bir gösterge olmaktadır. Bu değerlendirme, yaşa bağlı gelişimsel sürecin izlenmesinde objektif bir kriter sunmaktadır.⁵ Kronolojik yaşla yüksek düzeyde korelasyon göstermesi sayesinde pediatri, adli bilimler ve ortodonti gibi çok sayıda alanda yaygın biçimde kullanılmaktadır. Bu kapsamda, diş yaşı tahmini; gelişimsel anomalilerin saptanması, bireye özgü tedavi planlarının oluşturulması ve büyüme-gelişim sürecinin izlenmesinde sağlık profesyonellerine önemli katkılar sağlamaktadır.^{189, 190} Bu kapsamda diş yaşı, çalışmamızda da yer almakta olup farklı gözlemciler tarafından hesaplanan değerler karşılaştırmalı olarak analiz edildi.

Diş yaşı değerlendirmesinde çeşitli yöntemler kullanılmakla birlikte, çalışmamızda bu amaçla, en yaygın başvuru ve literatürde yüksek güvenilirliğe sahip olan Demirjian yöntemi tercih edilmiştir.¹⁹¹ Karadayı ve ark. tarafından yapılan çalışmada, Demirjian yöntemine göre hesaplanan diş yaşlarının, Fransız-Kanadalı

referans popölasyona kıyasla Türk çocuklarında daha yüksek bulunduđu ve kronolojik yaşa göre anlamlı düzeyde yüksek bulunduđu bildirilmiştir.¹⁹² Öte yandan, Karataş ve ark. tarafından Türk çocukları üzerinde gerçekleştirilen başka bir çalışmada ise, tüm grupta diş yaşının kronolojik yaştan daha düşük olduđu; bu farkın kız çocuklarında yaklaşık üçte bir yıl, erkek çocuklarında ise yarım yıla yakın olduđu bildirilmiştir.¹⁹³ Dolayısıyla literatürde yer alan farklı sonuçlar, Demirjian yönteminin referans popölasyon dışındaki gruplarda sınırlı uyum gösterdiğine işaret etmektedir. Mevcut çalışmada da, Türk çocukları üzerinde yapılan değerlendirmede, Demirjian yöntemiyle elde edilen diş yaşı değerleri kronolojik yaştan daha yüksek bulundu; bu durum, Karadayı ve ark. tarafından bildirilen bulgularla paralellik göstermekte ve yöntemin referans popölasyona dayalı sınırlılıklarını ortaya koymaktadır. Bu farklılığın nedenleri, yalnızca yöntemin referans popölasyona dayalı yapısıyla sınırlı kalmayıp; bireyler arası değişkenlik gösteren çevresel faktörlerle de ilişkilendirilmektedir. Nitekim, farklı araştırmacılar tarafından yapılan diş yaşı tahminleri, yalnızca farklı coğrafi bölgeler arasında değil, aynı bölge içerisindeki bireyler arasında dahi diş yaşı açısından belirli farklılıkların ortaya çıkabileceğini göstermektedir. Bu farklılıkların, sosyoekonomik düzey, beslenme alışkanlıkları ve genel yaşam tarzı gibi çevresel faktörlerden kaynaklanabileceği ileri sürülmektedir.^{194, 195} Benzer şekilde, Carelli ve ark.¹⁹⁶ tarafından Brezilyalı çocuklar üzerinde gerçekleştirilen çalışmada da, Demirjian yönteminin sistematik biçimde diş yaşı tahminini yüksek yaptığı bildirilmiş; Moca ve ark.¹⁹⁷ tarafından Romanya'daki çocuk popölasyonu üzerinde yapılan çalışmada da benzer sonuçlara ulaşılmıştır. Bu bağlamda, Demirjian ve Willems yöntemlerinin farklı etnik popölasyonlardaki doğruluğunu karşılaştıran bir meta-analiz çalışmasında¹⁹⁸, Demirjian yönteminin çoğu durumda diş yaşını gerçekte olduğundan yüksek tahmin etme eğiliminde olduğu, dolayısıyla farklı popölasyonlar arasında istatistiksel olarak anlamlı sapmalar

gösterdiği bildirilmiştir. Bu bulgular, farklı popülasyonlarda yöntemin kalibrasyon ihtiyacını ortaya koymakta ve çalışmamızın sonuçlarıyla örtüşmektedir. Demirjian yönteminin farklı etnik popülasyonlarda sistematik sapmalar gösterebildiği, çalışmamızda da olduğu gibi birçok araştırmada ortaya konmuştur. Ancak buna rağmen, bu yöntemin tercih edilmesinin temel nedeni, dış gelişim evrelerinin açık ve standart biçimde tanımlanmış olması, literatürde yaygın olarak kullanılması ve özellikle veri etiketleme sürecinde güvenilir bir referans sağlamasıdır. Yapay zekâ temelli modellerin eğitilmesi için doğru ve tekrarlanabilir etiketleme süreci kritik öneme sahiptir; Demirjian yöntemi, bu açıdan literatürde en fazla başvurulmuş ve karşılaştırmaya uygun referans yapıyı sunmaktadır.¹⁹⁹ Aynı zamanda, Demirjian evrelerinin yalnızca klasik dönüşüm tabloları ile değil, makine öğrenimi algoritmalarıyla birlikte kullanıldığında da yüksek doğruluk sağladığı gösterilmiştir. Nitekim Galibourg ve ark.²⁰⁰ tarafından yapılan çalışmada, Demirjian evreleme sistemini temel alan tüm makine öğrenimi modelleri, Willems referans yöntemine kıyasla daha düşük hata oranı ile daha doğru yaş tahminleri üretmiştir. Bu bulgular, Demirjian evreleme sisteminin yapay zekâ destekli dış yaş tahmini uygulamalarında etkili biçimde kullanılabileceğini ve bu bağlamda güvenilir bir temel oluşturduğunu ortaya koymaktadır. Hostiuc ve ark.¹⁹⁹ tarafından gerçekleştirilen bir meta-analiz çalışmasında ise, Demirjian yönteminin 16 yaş ve sonrasında kullanımında hata oranlarının anlamlı düzeyde arttığı vurgulanmıştır. Bu doğrultuda, mevcut çalışmada örneklem grubunun üst yaş sınırının 15 olarak belirlenmesi, yöntemin geçerliliğinin yüksek olduğu yaş aralığında değerlendirme yapılmasına olanak sağladı.

Son yıllarda ise, Demirjian yöntemi gibi geleneksel değerlendirme yaklaşımlarının daha hızlı ve standardize biçimde uygulanabilmesi amacıyla, yapay zekâ tabanlı sistemlerin geliştirilmesine yönelik çalışmalar artış göstermektedir. Bu sistemler, hem işlem süresini kısaltmakta hem de daha tutarlı ve tekrarlanabilir sonuçlar

sunmaktadır. Ayrıca, insan gözüyle fark edilmesi zor olan detayları tespit edebilmekte ve bu veriler arasındaki ilişkileri analiz edebilmektedir. Bu sayede, daha doğru tahminler yapılabilen ve hata oranları azaltılabilmektedir. Ancak karar verme süreçlerinin yorumlanabilirliği açısından sınırlılıklar barındırmaktadır.²⁰¹ Bu sorunun çözümü için çeşitli görselleştirme ve açıklayıcı yöntemler geliştirilmiş olsa da, derin öğrenme modellerinin karar verme sürecinin tam olarak anlaşılması günümüzde hâlâ önemli bir araştırma alanı olarak varlığını sürdürmektedir.²⁰²

Yapay zekâ uygulamalarının dental radyolojiye entegre edilmesinde, kullanılacak görüntüleme yönteminin uygunluğu da büyük önem taşımaktadır. Bu bağlamda, çalışmamızda panoramik radyografiler tercih edildi. Panoramik radyografiler, tüm maksillofasiyal yapının tek bir görüntüde elde edilebilmesini sağlayarak, mandibular sol daimi dişlerin gelişim evrelerinin aynı anda ve karşılaştırmalı biçimde değerlendirilmesine olanak tanımaktadır. Ayrıca bu radyografiler, düşük radyasyon dozu, non-invaziv yapısı ve klinik uygulamalarda yaygın kullanım kolaylığı nedeniyle hem etik hem de pratik açıdan önemli avantajlar sunmaktadır.²⁰³ Bu özellikleriyle, geniş örneklemelerin retrospektif olarak incelenmesine uygun bir veri kaynağı oluşturmakta ve Demirjian yöntemi gibi diş bazlı evreleme sistemlerinin uygulanmasını kolaylaştırmaktadır. Öte yandan, literatürde konik ışınlı bilgisayarlı tomografi (CBCT) görüntüleri kullanılarak gerçekleştirilen yaş tahmini çalışması da bulunmaktadır. Saric ve ark.²⁰⁴, CBCT görüntülerinden elde edilen bukkal alveolar kemik seviyelerini makine öğrenimiyle analiz ederek diş yaşı tahmini yapmıştır; ancak CBCT'nin daha yüksek radyasyon dozu ve sınırlı yaygınlığı nedeniyle, geniş örneklemli ve pediatrik odaklı çalışmalarda panoramik radyografiler hâlâ ilk tercih olmaya devam etmektedir. Bu bağlamda, panoramik radyografilerin CBCT'ye kıyasla daha düşük radyasyon dozu

taşıması ve etik açıdan çocuk hasta grubunda daha uygulanabilir olması, çalışmamızda tercih edilmesini desteklemiştir.

Bu doğrultuda, çalışmamızda Demirjian evreleme sistemine göre etiketlenmiş panoramik radyografiler kullanılarak, derin öğrenme temelli bir yapay zekâ modeli geliştirildi ve bu modelin gelişim evresi sınıflandırmadaki başarısı değerlendirildi. Yapay zekâ modelinin temel amacı, mandibular sol daimi dişlerin gelişim evrelerini otomatik olarak belirlemek olup, diş yaşı tahmini bu evrelerin Demirjian yöntemiyle puanlanması ve cinsiyete özgü dönüşüm tabloları kullanılarak manuel olarak hesaplanması yoluyla gerçekleştirildi. Modelin çıktıları, uzman hekim ve araştırma görevlisi tarafından yapılan manuel evrelemelerle karşılaştırıldı; bu karşılaştırma sonucunda, yapay zekâ modelinin sınıflandırma doğruluğu ve gözlemcilerle olan diş yaşı tespit uyumu çeşitli istatistiksel metrikler üzerinden analiz edildi.

Mevcut çalışmada geliştirilen yapay zekâ modelinin sınıflandırma performansı sonucunda, modelin diş gelişim evrelerini tespit etmede orta düzeyde bir başarı sergilediği görülmüştür. Nitekim, Kurt ve ark.²⁰⁵ tarafından gerçekleştirilen diş gelişim evrelerinin yapay zekâ ile sınıflandırılabilirliğini araştıran bir çalışmada elde edilen yüksek performans değerleri, modelin hem pozitif örnekleri neredeyse eksiksiz şekilde tespit ettiğini, hem de bu tespitlerin büyük ölçüde doğru sınıflandırmalarla sonuçlandığını ortaya koymaktadır. Buna karşılık, mevcut çalışmada özellikle yanlış pozitif sayısının görece yüksek olması, modelin kesinlik değerini düşürmüş ve buna bağlı olarak F1 skorunu da olumsuz etkilemiştir. Ayrıca, duyarlılık değeri de Kurt ve ark.'nın çalışmasında bildirilen seviyeye ulaşamamıştır. Bu farklılıkların; kullanılan model mimarisi, veri setinin niteliği, etiketleme yöntemi, etiketleyici gözlemcinin uzmanlık düzeyi, eğitim süreci ve eşik değeri ayarları gibi çeşitli faktörlerden kaynaklanıyor olabildiği düşünülmektedir. Mevcut bulgular, geliştirilen modelin performansını artırmak

amacıyla ileri düzey optimizasyon tekniklerine ihtiyaç duyulduğunu göstermektedir. Bu iyileştirmelerle birlikte, modelin hem klinik hem de adli uygulamalar açısından daha güvenilir ve tutarlı sonuçlar verebilmesi hedeflenmektedir.

Benzer şekilde, Roh ve ark.²⁰⁶ tarafından gerçekleştirilen çalışmada da, Demirjian yöntemi temel alınarak diş yaşı tahmini amacıyla YSA tabanlı bir model geliştirilmiştir. Her iki çalışmada da mandibular sol daimi dişlerin gelişim evreleri esas alınmış ve panoramik radyografiler kullanılmıştır. Söz konusu çalışmada, dişlerin gelişim evreleri gözlemciler tarafından Demirjian etiketlemesi kullanılarak manuel olarak belirlenmiş ve bu evreler sinir ağı modeline giriş verisi olarak tanımlanarak doğrudan yaş tahmini gerçekleştirilmiştir. Bu yönüyle Roh ve ark.'nın çalışması, Demirjian etiketlerine dayalı olarak yaş tahmini yapan tek aşamalı bir regresyon modeli sunarken; mevcut çalışmada, aynı etiketleme sistemi kullanılarak gelişim evreleri yapay zekâ aracılığıyla otomatik olarak sınıflandırıldı ve sonrasında yaş tahmini, Demirjian puanlama sistemine göre manuel olarak hesaplandı. Bu durum, her iki çalışmanın Demirjian sistemine dayanmasına rağmen, yapay zekâ uygulamasının süreçte farklı noktalarda devreye girmesi bakımından önemli bir yöntemsel ayrım oluşturmaktadır. Roh ve ark. tarafından geliştirilen tek aşamalı model, doğrudan yaş tahmini amacı taşıması nedeniyle daha kompakt bir sistem sunarken; mevcut çalışmadaki iki aşamalı yaklaşım ise, evrelerin bağımsız biçimde sınıflandırılmasına olanak tanıyarak model çıktılarının şeffaflığını ve yorumlanabilirliğini artırmaktadır.

Roh ve ark.²⁰⁶ çalışmasında, yapay zekâ modellerinin yaş tahmininde geleneksel yöntemler kadar doğru sonuçlar verdiği, ancak daha üstün olduklarının net biçimde gösterilemediği belirtilmiştir. Model, her iki cinsiyette ortalama olarak doğru tahminler yapmış olsa da, erkek bireylerde bazı büyük sapmalar gözlenmiştir. Mevcut çalışmada ise yapay zekâ modelinin sınıflandırma başarısı genel olarak orta düzeyde kaldı; özellikle

birçok gelişim evresinde sınırlı sayıda doğru tahmin yapılabildi. Bununla birlikte, her iki çalışmada da yapay zekâ modelinin erkek bireylerde daha yüksek dış yaşı tahminleri üretmesi dikkat çekicidir. Bu durum, modelin erkek bireylerde daha büyük sapmalarla tahmin yaptığına işaret etmekte ve cinsiyete bağlı farklılıkların yapay zekâ performansı üzerindeki etkisinin değerlendirilmesi gerektiğini göstermektedir. Ayrıca, mevcut çalışmada daha geniş bir veri seti (n=1910) kullanılmış olması, modelin genellenebilirliğini arttırdı ve gözlemciler arası karşılaştırmalarla desteklenerek değerlendirme süreci daha ayrıntılı olarak ele alındı. Buna karşılık, Roh ve ark. tarafından yürütülen çalışmada daha sınırlı sayıda (n=1196) görüntü kullanılmıştır.

Yapay zekâ temelli modellerin güvenilirliğini değerlendirirken, kullanılan yöntemin gözlemciler arasında da tutarlı sonuçlar üretilip üretilmediği de önem taşımaktadır. Sakaryalı ve ark.²⁰⁷ çalışmasında, Demirjian ve Moorrees yöntemleri iki farklı araştırmacı tarafından uygulanmış ve her iki yöntemde de yüksek gözlemci uyumu saptanmıştır. Her ne kadar bu çalışma yapay zekâ temelli bir model içermese de, Demirjian yönteminin farklı gözlemciler tarafından benzer sonuçlar vermesi, yöntemin güvenilirliğini ortaya koymaktadır. Mevcut çalışmada ise yalnızca Demirjian yöntemi kullanıldı; uzman hekim, araştırma görevlisi ve yapay zekâ modeli değerlendirmeleri karşılaştırıldı. Sakaryalı ve ark.'nın manuel değerlendirmelerle elde ettiği yüksek uyum, bu çalışmada ICC analizleriyle yapay zekâ ve insan gözlemciler arasında da doğrulandı.

Literatürde, farklı dış yaşı tahmin yöntemlerinin yapay zekâ destekli uygulamalarla karşılaştırıldığı çalışmalardan biri olan Yavuz ve ark.²⁰⁸ tarafından gerçekleştirilen çalışmada, Türk çocuklarına ait veriler kullanılarak çeşitli metodolojilerin doğrulukları derin öğrenme modelleri aracılığıyla analiz edilmiştir. Bu çalışmada, derin öğrenme algoritmasının diğer yöntemlere kıyasla daha düşük başarı gösterdiği ve tahmin performansının görece zayıf olduğu bildirilmiştir. Benzer şekilde,

mevcut çalışmada da yapay zekâ modelinin gelişim evresi sınıflandırma başarısı ve bu sınıflandırmalardan elde edilen diş yaşı değerleri, uzman hekim değerlendirmelerine göre daha düşük düzeyde kaldı. Bununla birlikte bu çalışma ile metodolojik açıdan dikkat çeken önemli bir farklılık söz konusudur. Yavuz ve ark. çalışmasında yapay zekâ modeli doğrudan yaş tahmini yapmak üzere yapılandırılmışken, mevcut çalışmada model yalnızca gelişim evresi sınıflandırması gerçekleştirdi; yaş tahmini ise Demirjian yöntemi kullanılarak manuel olarak hesaplandı. Bu yönüyle, iki çalışma arasında yapay zekâ çıktılarının niteliği bakımından temel bir fark mevcuttur. Sonuç olarak, her iki çalışmada da yapay zekâ modellerinin mevcut haliyle sınırlı başarı gösterdiği; ancak yöntemlerin geliştirilmesi durumunda Türk çocuk popülasyonunda klinik olarak kullanılabilir potansiyel taşıdığı söylenebilir.

Literatürde Ong ve ark.²⁰⁹ yaptığı benzer bir çalışmada da panoramik radyografiler üzerinden otomatik diş gelişim evresi sınıflandırması yapılmış ve her bir işlem için performansı değerlendirmiştir. İlgili çalışma ve mevcut çalışmanın bulguları birlikte değerlendirildiğinde, yapay zekâ modellerinin diş gelişim evresi sınıflandırmasında genel olarak sınırlı başarı gösterdiği ve bu alandaki performanslarının hâlen yetersiz kaldığı görülmektedir. İlgili çalışmada, molar diş modellerinde daha yüksek sınıflandırma doğruluğu elde edilirken, kesici diş modellerinde düşük F1 skorları raporlanmıştır. Mevcut çalışmada ise en yüksek F1 skoru 31 numaralı dişin F evresinde gözlemlendi; ancak diğer dişlerde modelin tahminleri, doğru olarak kabul edilen uzman hekimin değerlendirmeleriyle büyük ölçüde uyuşmadı. Bu durum, ilgili çalışmada da olduğu gibi, bazı evrelerin veya diş tiplerinin yapay zekâ tarafından ayırt edilmesinde hâlen güçlükler yaşandığını göstermektedir. İlgili çalışmada, yalnızca eksiksiz ve sağlam yedi daimi dişi içeren panoramik radyografların kullanılmış olmasının, modelin tespit performansını artırmış olabileceği ifade edilmiştir. Benzer şekilde, mevcut çalışmada da

dahil edilme kriterleri doğrultusunda eksik veya anomalili dişler dışlandı, yalnızca tanısal olarak yeterli ve tüm hedef dişleri içeren görüntüler değerlendirmeye alındı. Bu durumun, modelin daha yüksek doğrulukla diş yaşı tespiti yapmasında etkili olmuş olabileceği; ancak, bu seçici yaklaşım nedeniyle modelin, klinikte karşılaşılabilecek eksik diş, düşük kaliteli görüntü gibi farklı durumlara yeterince uyum sağlayamayabileceği düşünülmektedir. Bu durum, modelin kontrollü koşullarda elde edilen başarı düzeyinin, gerçek yaşam senaryolarında aynı şekilde yansımayabileceğine işaret etmektedir. İlgili çalışmada, YOLOv5 ve U-Net modelleriyle yürütülen nesne tespiti ve segmentasyon görevlerinde oldukça yüksek doğruluk bildirilmiştir. Buna karşılık, mevcut çalışmada kullanılan YOLOv8x modeli, hem nesne tespiti hem de piksel düzeyinde segmentasyon yapabilme yeteneğiyle daha kapsamlı bir yaklaşım sunmakta; ancak doğruluk düzeyi ilgili çalışmadaki kadar yüksek olmamakla birlikte, genel olarak dengeli ve uygulanabilir bir performans sergilemektedir. Bu durum, modelin farklı görevleri bir arada yürütebilme kapasitesine rağmen bazı senaryolarda optimizasyon gerektirebileceğini; ayrıca yapay zekâ modellerinin dental radyografilerdeki segmentasyon ve tespit görevlerinde uygulanabilir olmakla birlikte, performanslarının örneklem çeşitliliği ve klinik gerçekliğe uygun testlerle değerlendirilmesinin kritik önem taşıdığını göstermektedir.

Wallraff ve ark.²¹⁰ tarafından yürütülen çalışmada, 11–20 yaş aralığındaki bireylerden elde edilen 14.000 panoramik radyografik görüntü kullanılarak yapay zekâ temelli diş yaş tahmini gerçekleştirilmiş ve geliştirilen modelin, %17,52 hata oranı ile klinisyenlerden daha yüksek doğrulukta sonuçlar verdiği bildirilmiştir. Buna karşılık, mevcut çalışmada daha erken yaş grubu olan 5–14 yaş aralığı incelendi; yaş tahmini, otomatik gelişim evresi sınıflandırmasının ardından Demirjian yöntemi kullanılarak manuel olarak hesaplandı. Elde edilen bulgular doğrultusunda mevcut çalışmada geliştirilen yapay zekâ modelinin doğruluk düzeyi, ilgili çalışmada bildirilen model kadar

yüksek olmadı; özellikle bazı gelişim evrelerinde sınıflandırma başarısının sınırlı kaldığı gözlemlendi. Bu durumun, yaş aralığı farkı, veri seti hacmi ve kullanılan yöntemsel yaklaşım gibi faktörlerden kaynaklanabileceği düşünülmektedir.

Galibourg ve ark.²⁰⁰ çalışmasında, diş yaşı tahmini amacıyla klasik yöntemler ile makine öğrenimi algoritmalarını karşılaştırılmış ve makine öğrenimi tabanlı modellerin daha yüksek doğruluk sağladığı bildirilmiştir. Nitekim, Wu ve ark.²¹¹ tarafından yürütülen çalışmada da, makine öğrenimi yöntemlerinin Demirjian evrelerini temel alarak Willems ve Demirjian gibi referans yöntemlerden daha yüksek doğruluk sağladığı gösterilmiştir. Bu bağlamda, ML modelleri çok sayıda bireye ait gerçek verilerden öğrenerek tahmin gerçekleştirdiği için, sabit dönüşüm tablolarına dayanan geleneksel yöntemlerin aksine, bireyler arası biyolojik varyasyonları daha etkili şekilde dikkate alabilmektedir. Bu durum, diş yaşı tahmini uygulamalarında klasik sistemlerin ötesine geçilerek daha esnek, veriye dayalı ve adaptif modellerin geliştirilmesinin önemini ortaya koymaktadır. Buna karşılık, mevcut çalışmada yaş tahmini doğrudan yapay zekâ tespit edilmedi; yalnızca gelişim evresi sınıflandırması için derin öğrenme tabanlı bir model kullanıldı, yaş tahmini ise Demirjian yöntemine ait sabit ve cinsiyete özgü dönüşüm tabloları aracılığıyla manuel olarak hesaplandı. Bu nedenle, bireysel farklılıklara duyarlılık açısından, makine öğrenimi modellerine kıyasla daha sınırlı bir yaklaşım benimsenmiştir; çünkü makine öğrenimi modelleri, gelişim evreleri ile yaş arasındaki ilişkiyi sabit tablolar yerine doğrudan verilerden öğrenerek bu ilişkiyi kendisi oluşturur ve böylece bireyler arası değişkenliğe daha esnek biçimde uyum sağlayabilir. Ayrıca, gelişim evrelerinin manuel olarak tanımlanmasına dayalı etiketleme süreci dikkatli biçimde yürütülmüş olsa da, bu sürece bağlı gözlemci kaynaklı farklılıkların, modelin sınıflandırma başarısını etkileyebilecek bir sınırlılık oluşturmuş olabileceği düşünülmektedir. Nitekim, elde edilen bulgular doğrultusunda, mevcut çalışmada kullanılan derin öğrenme modelinin

sınıflandırma başarısı sınırlı kaldı ve nihai yaş tahmininde, klasik yönteme göre daha düşük doğruluk elde edildi.

Literatürde yer alan pek çok çalışmada (Oliveira ve ark.²¹²., Roh ve ark.²⁰⁶, Yavuz ve ark.²⁰⁸, Wallraff ve ark.²¹⁰), yapay zekâ modelleri doğrudan diş yaşı tahmini yapacak şekilde kurgulanmış ve model çıktısı doğrudan yaş değeri olacak şekilde değerlendirilmiştir. Mevcut çalışmada ise bu yaklaşımdan farklı olarak, yapay zekâ modeli yalnızca mandibular sol daimi dişlerin gelişim evrelerini sınıflandırdı; yaş tahmini ise bu evrelerin Demirjian yöntemiyle puanlanması yoluyla manuel olarak gerçekleştirildi. Bu yönüyle çalışmamız, literatürdeki pek çok çalışmadan yapısal olarak ayrılmaktadır. Bu metodolojik farklılık, bir yandan modelin çıktılarının yorumlanabilirliğini ve şeffaflığını artırmakta; hangi dişin hangi evrede ne ölçüde doğru sınıflandırıldığını ayrı ayrı analiz etme olanağı sunmaktadır. Özellikle pediatrik yaş grubunda, diş gelişimin oldukça dinamik ve bireysel farklılık gösterebilir olması nedeniyle bu düzeyde bir ayrıntılandırma klinik açıdan önem arz etmektedir. Ayrıca, evre düzeyindeki hataların kaynağının belirlenebilmesi, modelin eğitiminde yapılacak gelecekteki iyileştirmeler açısından da yol göstericidir. Öte yandan, bu metodolojik yapı nedeniyle modelin genel başarısı, literatürdeki doğrudan diş yaşı tahmini yapan çalışmalarla doğrudan karşılaştırılamamaktadır. Çünkü bu tür sistemlerde kullanılan genel geçer performans metrikleri, mevcut çalışmada kullanılan iki aşamalı yaklaşım nedeniyle doğrudan uygulanabilir değildir. Bu durum, modelin daha geniş veri setlerinde ya da farklı popülasyonlarda nasıl genellenebileceğine dair değerlendirmeleri dolaylı hale getirmektedir. Bununla birlikte, mevcut çalışmadaki yapı modelin sınıflandırma düzeyinde objektif biçimde test edilmesini mümkün kıldı ve gelişim evrelerine ilişkin güçlü ya da zayıf yönlerinin ayrı ayrı ortaya konmasına olanak tanıdı. Dolayısıyla, bu yapı literatürdeki doğrudan regresyon modellerine göre daha fazla açıklanabilirlik

sunarken, yaş tahmini doğruluğunun kıyaslamasında farklı istatistiksel parametrelerin kullanılması gerekliliğini de beraberinde getirdi.

Bununla birlikte, çalışmanın bazı sınırlılıkları bulunmaktadır. Öncelikle, gelişim evrelerinin etiketlenmesi uzman bir hekim yerine araştırma görevlisi tarafından manuel olarak yapılmış olup, bu durum etiketleme sürecinde gözlemciye bağlı hataların oluşma olasılığını artırmış ve modelin öğrenme sürecini etkileyebilecek bir faktör oluşturmuştur. Bu durum, modelin eğitim düzeyine daha yakın gözlemcilerle daha tutarlı çalıştığını ve uzman düzeyindeki karmaşık ayırt edici etiketlemelere henüz ulaşamadığını göstermektedir. Ayrıca, geliştirilen yapay zekâ modeli yalnızca gelişim evresi sınıflandırmasına odaklandı; yaş tahmini doğrudan model tarafından yapılmadı, evre sınıflandırmaları sonrasında manuel olarak hesaplandı. Bu yapı, sistemin tam otomatik yaş tahmini sağlayamaması nedeniyle süreç bütünlüğünü sınırlamaktadır. Öte yandan, dahil edilme kriterleri doğrultusunda eksik, anomalili veya tanısız olarak yetersiz panoramik radyograflar çalışma dışında bırakıldığından, geliştirilen modelin klinik gerçekliğe tam olarak genellenebilirliğinin sınırlı kalmış olabildiği düşünülmektedir.

Tüm bu sınırlılıklara rağmen, çalışmada kullanılan iki aşamalı yapı sayesinde, yapay zekâ modelinin gelişim evresi düzeyinde gösterdiği başarı ayrıntılı biçimde değerlendirilebilmiş ve sınıflandırma sürecine ilişkin güçlü ve zayıf yönler ayrı ayrı ortaya konabilmiştir. Bu yaklaşım, modelin iyileştirilmesi gereken noktalarının belirlenmesini kolaylaştırmakta ve gelecekte yapılacak çalışmalar için yol gösterici nitelik taşımaktadır. Ayrıca, modelin yalnızca sınıflandırma görevine odaklanmış olması, yaş tahmini sürecinin geleneksel yöntemle manuel biçimde gerçekleştirilmesine olanak tanıyarak, literatürdeki doğrudan yaş tahmini yapan sistemlerden yapısal olarak ayrılmasını sağlamıştır. Bu durum, hem metodolojik farklılıkların vurgulanmasına hem de karşılaştırmalı analizlerin daha kontrollü biçimde yapılmasına katkı sunmaktadır.

Buna ek olarak, çalışmada uzman hekim, araştırma görevlisi ve yapay zekâ modeli tarafından gerçekleştirilen Demirjian değerlendirmeleri karşılaştırılmış; bu değerlendirmeler arasındaki uyum, ICC analizleri aracılığıyla doğrulanmıştır. Bu sayede, gözlemciler arası güvenilirlik istatistiksel olarak ortaya konmuştur. Aynı zamanda, yalnızca Türk çocuk popülasyonuna özgü örneklem grubu ile çalışılmış olması, yöntemin popülasyon bazlı geçerliliğinin değerlendirilmesine olanak sağlamış ve bölgesel farklılıkların etkisini incelemeye yönelik katkı sunmuştur.

Tüm bu değerlendirmeler doğrultusunda, elde edilen bulgular istatistiksel olarak da test edildi ve şu sonuca ulaşıldı:

"H₀: Uzman diş hekimi ve araştırma görevlisi tarafından Demirjian yöntemine göre yapılan diş yaşı tahminleri ile derin öğrenme temelli yapay zekâ uygulaması tarafından yapılan tahminler arasında istatistiksel olarak anlamlı bir fark yoktur." hipotezi reddedildi,

"H₁: Uzman diş hekimi ve araştırma görevlisi tarafından Demirjian yöntemine göre yapılan diş yaşı tahminleri ile derin öğrenme temelli yapay zekâ uygulaması tarafından yapılan tahminler arasında istatistiksel olarak anlamlı bir fark vardır." hipotezi kabul edildi.

6. SONUÇ ve ÖNERİLER

Sonuç olarak, bu çalışmada geliştirilen yapay zekâ modelinin mandibular sol daimi dişlerin gelişim evrelerini sınıflandırmada sınırlı düzeyde doğruluk sergilediği ve özellikle uzman gözlemci ile yapılan karşılaştırmalarda daha düşük uyum gösterdiği saptanmıştır. Araştırma görevlisi ile yapılan değerlendirmelerde ise modelin daha tutarlı sonuçlar verdiği görülmüştür. Genel örnekleme üç gözlemci arasında yüksek düzeyde uyum bulunması, mutlak değer farklılıklarına rağmen modelin sıralı ilişkiyi koruyabildiğini ve klinik uygulamalar açısından umut vadettiğini ortaya koymaktadır.

Tüm bu değerlendirmeler doğrultusunda çalışmadan elde edilen temel bulgular aşağıda maddeler hâlinde özetlenmiştir:

- Diş gelişim evrelerinin sınıflandırılmasında geliştirilen yapay zekâ modeli orta düzeyde doğruluk göstermiştir.
- Erkek bireylerde, hem araştırma görevlisi hem de yapay zekâ tarafından yapılan diş yaşı tahminleri, kronolojik yaştan anlamlı biçimde yüksek bulunmuştur.
- Yapay zekâ, genel olarak uzman ve araştırma görevlisine kıyasla daha yüksek diş yaşı değerleri üretmiştir.
- Tüm gözlemciler arasında yüksek düzeyde uyum saptanmıştır, bu da yöntemler arasında güçlü bir korelasyon olduğunu göstermektedir.
- Yapay zekâ ve araştırma görevlisi, kronolojik yaştan anlamlı düzeyde daha yüksek tahmin yapmıştır.
- Yapay zekâ, uzman hekime kıyasla da anlamlı düzeyde daha yüksek yaş tahmini yapmıştır.

Öte yandan, yaş tahmin sürecinin manuel olarak gerçekleştirilmiş olması modelin tam otomatik bir sistem olarak değerlendirilememesine yol açmış ve süreç bütünlüğünü sınırlamıştır. Modelin yalnızca gelişim evresi sınıflandırmasına odaklanması da bu sınırlılığı pekiştirmiştir. Bu nedenle, gelecekte sınıflandırma adımının ardından yaş tahmininin de model bünyesinde otomatik olarak gerçekleştirilmesi; işlem süresini azaltarak, klinik uygulamalarda doğruluk, hız ve verimliliği artıracaktır.

Bu sınırlılıklar göz önüne alındığında, ileriye dönük çalışmalarda:

- Daha çeşitli ve temsil gücü yüksek örneklemeler kullanılması,
- Etiketleme sürecinde uzman gözlemcilerin doğrudan yer alması,
- Gelişim evresi sınıflandırmasına ek olarak otomatik yaş tahmini yapabilen sistemlerin geliştirilmesi,
- Model çıktılarının yorumlanabilirliğini artırmaya yönelik açıklayıcı yapay zekâ tekniklerinin entegre edilmesi
- Modelin doğruluk düzeyini artırmak amacıyla ileri düzey optimizasyon tekniklerinin uygulanması

modelin doğruluk ve klinik geçerliliğinin daha kapsamlı biçimde değerlendirilmesine olanak sağlayacaktır.

KAYNAKLAR

1. Huda TF, Bowman JE. Age determination from dental microstructure in juveniles. *Am. J. Phys. Anthropol.* , 1995; 97: 135-50.
2. McKenna CJ, James H, Taylor JA, ve ark. Tooth development standards for South Australia. *Aust Dent J*, 2002; 47: 223-7.
3. Maber M, Liversidge HM, Hector MP. Accuracy of age estimation of radiographic methods using developing teeth. *Forensic Sci Int*, 2006; 159 Suppl 1: S68-73.
4. Black SM, Scheuer JL. T.F.J. Huda and J.E. Bowman, Age determination from dental microstructure in juveniles: *American Journal of Physical Anthropology*, 1995 vol. 97: 135-150. *Am J Phys Anthropol*, 1996; 101: 305-6.
5. Willems G. A review of the most commonly used dental age estimation techniques. *J Forensic Odontostomatol*, 2001; 19: 9-17.
6. Wu TJ, Tsai CL, Gao QZ, ve ark. The Application of Artificial-Intelligence-Assisted Dental Age Assessment in Children with Growth Delay. *J Pers Med*, 2022; 12:
7. Park WJ, Park JB. History and application of artificial neural networks in dentistry. *Eur J Dent*, 2018; 12: 594-601.
8. Neri E, de Souza N, Brady A, ve ark. What the radiologist should know about artificial intelligence – an ESR white paper. *Insights into Imaging*, 2019; 10: 44.
9. Syed AB, Zoga AC. Artificial Intelligence in Radiology: Current Technology and Future Directions. *Semin Musculoskelet Radiol*, 2018; 22: 540-545.
10. Poedjiastoeti W, Suebnukarn S. Application of Convolutional Neural Network in the Diagnosis of Jaw Tumors. *Healthc Inform Res*, 2018; 24: 236-241.
11. Hung K, Montalvao C, Tanaka R, ve ark. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac Radiol*, 2020; 49: 20190107.
12. Nanci A. *Ten Cate's Oral Histology: Development, Structure, and Function*, 9. St. Louis, Elsevier, 2017.
13. Davis WL. *Oral Histology: Cell Structure and Function*, Philadelphia, W.B. Saunders Company, 1986: 37–54.
14. Miletich I, Sharpe PT. Normal and abnormal dental development. *Hum Mol Genet*, 2003; 12 Spec No 1: R69-73.

15. Qiu T, Teshima T, Hovorakova M, ve ark. Development of the Vestibular Lamina in Human Embryos: Morphogenesis and Vestibule Formation. *Frontiers in Physiology*, 2020; 11.
16. Young BOD, Geraldine; Woodford, Philip. *Wheater's Functional Histology: A Text and Colour Atlas*, 6th Edition. London, UK, Churchill Livingstone, 2013.
17. Parada C, Chai Y, Sharpe P. Chapter 20 - Functional Significance of Cranial Neural Crest Cells During Tooth Development and Regeneration. In: Trainor PA, editor. *Neural Crest Cells*. Boston: Academic Press; 2014. p. 423-439.
18. Mitsiadis TA, Chéraud Y, Sharpe P, ve ark. Development of teeth in chick embryos after mouse neural crest transplantations. *Proc Natl Acad Sci U S A*, 2003; 100: 6541-5.
19. Ülgen M. Anomaliler, sefalometri, etioloji, büyüme ve gelişim, tanı, İstanbul, Yeditepe Üniversitesi Yayınları, 2000: 2-3.
20. Rathee M, Jain P. *Embryology, Teeth*. StatPearls. Treasure Island (FL): StatPearls Publishing Copyright © 2025, StatPearls Publishing LLC.; 2025.
21. Smith CE. Cellular and chemical events during enamel maturation. *Crit Rev Oral Biol Med*, 1998; 9: 128-61.
22. Erbudak H, Ozbek M, Uysal S, ve ark. Application of Kvaal et al.'s age estimation method to panoramic radiographs from Turkish individuals. *Forensic Sci Int*, 2012; 219: 141-6.
23. Thesleff I. The genetic basis of tooth development and dental defects. *Am J Med Genet A*, 2006; 140: 2530-5.
24. Bartlett JD, Simmer JP. Proteinases in developing dental enamel. *Crit Rev Oral Biol Med*, 1999; 10: 425-41.
25. Lacruz RS, Habelitz S, Wright JT, ve ark. Dental Enamel Formation And Implications For Oral Health And Disease. *Physiol Rev*, 2017; 97: 939-993.
26. Gençer MDG, Kırzioğlu Z. Gelişimsel Mine Defekti Görülen Dişlerde Rezin İnfiltrasyon Sisteminin Renk Maskeleme Etkisi. *Black Sea Journal of Health Science*, 2018; 1: 70-76.
27. Özbek PDE, Öğrencisi D, Gedikli S, ve ark. Dişin Embriyolojik Gelişimini Düzenleyen Sinyal Molekülleri. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi*, 2012; 2012: 217-223.
28. Nanci A. *Ten Cate's Oral Histology: Development, Structure, and Function* 6th ed. St. Louis, Mosby, 2003.

29. McDonald REA, D.R. Dentistry for the Child and Adolescent, 7th ed. St. Louis, Mosby, 2005.
30. Emeksiz C. Hipotiroidili Çocuk Hastalarda İki Farklı Metotla Diş Yaşı Tahmini: Karadeniz Teknik Üniversitesi Diş Hekimliği Fakültesi; 2022.
31. Bosshardt DD. Are cementoblasts a subpopulation of osteoblasts or a unique phenotype? J Dent Res, 2005; 84: 390-406.
32. Diekwisch T. The developmental biology of cementum. The International journal of developmental biology, 2001; 45: 695-706.
33. Foster BL, Popowics TE, Fong HK, ve ark. Advances in defining regulators of cementum development and periodontal regeneration. Curr Top Dev Biol, 2007; 78: 47-126.
34. Foster B, Somerman M, McCauley L. Mineralized tissues in oral and craniofacial science., 2012.
35. Nanci A. Ten Cate's oral histology: Development, structure, and function 10th ed. Elsevier., 2023.
36. Avery JK, & Chiego, D. J. . Essentials of oral histology and embryology: A clinical approach, 4th ed. Elsevier Health Sciences., 2015.
37. Tziafas D, Kodonas K. Differentiation potential of dental papilla, dental pulp, and apical papilla progenitor cells. J Endod, 2010; 36: 781-9.
38. Li J, Parada C, Chai Y. Cellular and molecular mechanisms of tooth root development. Development, 2017; 144: 374-384.
39. Ten Cate AR. The role of epithelium in the development, structure and function of the tissues of tooth support. Oral Dis, 1996; 2: 55-62.
40. Luder HU. Malformations of the tooth root in humans. Front Physiol, 2015; 6: 307.
41. He W, Fu Y, Yao S, ve ark. Programmed cell death of periodontal ligament cells. J Cell Physiol, 2023; 238: 1768-1787.
42. Palmer RM, Lumsden AG. Development of periodontal ligament and alveolar bone in homografted recombinations of enamel organs and papillary, pulpal and follicular mesenchyme in the mouse. Arch Oral Biol, 1987; 32: 281-9.
43. Cho MI, Garant PR. Development and general structure of the periodontium. Periodontol 2000, 2000; 24: 9-27.
44. Kreiborg S, Jensen BL. Tooth formation and eruption - lessons learnt from cleidocranial dysplasia. Eur J Oral Sci, 2018; 126 Suppl 1: 72-80.

45. Marks SC, Jr., Schroeder HE. Tooth eruption: theories and facts. *Anat Rec*, 1996; 245: 374-93.
46. Craddock HL YC. Eruptive tooth movement — the current state of knowledge. *British Dental Journal*, 2004; 197: 385–391
47. Andreasen JO, Petersen JK, Laskin DM. Textbook and color atlas of tooth impactions: diagnosis • treatment • prevention; 1997.
48. Proffit WR FH, Sarver DM. Contemporary Orthodontics 6th Edition St. Louis, Missouri Elsevier, 2019.
49. Craddock HL, Youngson CC. Eruptive tooth movement — the current state of knowledge. *British Dental Journal*, 2004; 197: 385-391.
50. Çayönü S, Yüksel B, Sari Ş. Development of Occlusion From the Toothless Period Up to the Permanent Dentition. *Türkiye Klinikleri Journal of Dental Sciences*, 2018; 26.
51. Demirel T, Bodrumlu EH. Sürme Anomalileri. *J. Dent. Sci.*, 2018; 141-146.
52. Kilinç G, Edem P, GÜNay T, ve ark. Common Maternal Complaints and Approaches Associated with the Eruption of Their Children's Primary Teeth. *Türkiye Klinikleri J. Dent. Sci.*, 2015; 21: 90-94.
53. Marwah N. Textbook of Pediatric Dentistry, 5rd. New Delhi, Jaypee Brothers Medical Publishers Pvt Ltd, 2018.
54. Terlaje RD, Donly KJ. Treatment planning for space maintenance in the primary and mixed dentition. *ASDC J Dent Child*, 2001; 68: 109-14, 80.
55. Burcu Nihan YÜ K, Şaziye S. Dişsiz Dönemden Daimi Dişlenme Sürecine Kadar Oklüzyonun Kurulumu. *Türkiye Klinikleri Diş Hekimliği Bilimleri Dergisi*, 2020; 26: 110-121.
56. Ngan PW, Wei SH, Yen PK. Orthodontic treatment of the primary dentition. *J Am Dent Assoc*, 1988; 116: 336-40.
57. Sandalli N, Cildir S, Hacinlioglu N. Çocuklarda kapanış ilişkileri ve oklüzyon. *Cumhuriyet Dental Journal*, 2011; 12:
58. Ülgen M. Anomaliler, Sefalometri, Etiyoloji, Büyüme ve Gelişim, Tanı, Ar Basım, 1983: 309–352.
59. Tooth eruption: The permanent teeth. *J. Am. Dent. Assoc.*, 2006; 137: 127.
60. Özdiler E. Bölüm 6: Dentisyonun gelişimi, 1. Ankara, Gümüş Kitabevi, 2015: 110-140.

61. Simmons K, Greulich WW. Menarcheal age and the height, weight, and skeletal age of girls age 7 to 17 years. *J. Pediatr.*, 1943; 22: 518-548.
62. Schmeling A, Geserick G, Reisinger W, ve ark. Age estimation. *Forensic Sci Int*, 2007; 165: 178-81.
63. Bishara SE. Chapter 5: Development of the dental occlusion, 3. Philadelphia, WB Saunders Company 2001.
64. Patti ADA, G. P. Establishment of occlusion, 1. Paris, Quintessence 2005: 15–22.
65. Proffit WR. Early stages of development, 4. St. Louis, Mosby Year Book, 2007: 167–268.
66. Büken B, Demir F, Buken E. Evaluation of Cases Sent for Age Estimation to Forensic Medicine Department Between 2001 and 2003 Years and Difficulties in Forensic Practice. *Düzce Med J*, 2003; 5: 18-23.
67. Baransel A, Büken B, Tokdemir M, ve ark. Assessing the Age Determination Cases Which Have Been Analyzed at Forensic Medicine Departments of 5 Different Region's Universities in Turkey Between Years 1998-2005. *Türkiye Klinikleri Journal of Medical Sciences*, 2009; 29: 304-313.
68. Kaya K, ÇEKİN N. Age Estimation in Children. *Türkiye Klinikleri Journal of Forensic Medicine and Forensic Sciences*, 2018; 15.
69. Çitir M, Karşlıoğlu H. Methods of age determination in forensic dentistry. *Yeditepe J Dent*, 2023; 19: 150-159.
70. Schour IM, M. The development of the human dentition. *J. Am. Dent. Assoc.*, 1941; 28: 1153–1160.
71. Alqahtani S, Hector M, Liversidge H. Accuracy of Dental Age Estimation Charts: Schour and Massler, Ubelaker and the London Atlas. *American journal of physical anthropology*, 2014; 154.
72. George G, Chatra L, Shenoy P, ve ark. Age determination by schour and massler method: A forensic study. *International Journal of Forensic Odontology*, 2018; 3: 36.
73. Gleiser I, Hunt EE, Jr. The permanent mandibular first molar: its calcification, eruption and decay. *Am J Phys Anthropol*, 1955; 13: 253-83.
74. Demirjian A, Goldstein H, Tanner JM. A new system of dental age assessment. *Hum Biol*, 1973; 45: 211-27.
75. Nolla CM. *Dentistry for the Child and Adolescent*, C.V. Mosby Co., 1960: 113–126.

76. Sehrawat JS, Singh M, Sharma V. Forensic Dental Age Estimation of Sub-Adult Individuals Using Nolla's Radiographic Method: A Systematic Review and Meta-Analysis. *Braz. J. Forensic Sci., Medical Law and Bioethics*, 2016; 6: 32-46.
77. Koch G, Poulsen S, Espelid I, ve ark. *Pediatric dentistry: a clinical approach*, John Wiley & Sons, 2017:
78. Haavikko K. The formation and the alveolar and clinical eruption of the permanent teeth. An orthopantomographic study. *Proc. Finn. Dent. Soc.*, 1974; 70: 104–170.
79. Moorrees CF, Fanning EA, Hunt EE, Jr. Age Variation Of Formation Stages For Ten Permanent Teeth. *J Dent Res*, 1963; 42: 1490-502.
80. Anderson DL, Thompson GW, Popovich F. Age of attainment of mineralization stages of the permanent dentition. *J Forensic Sci*, 1976; 21: 191-200.
81. Nyström M, Haataja J, Kataja M, ve ark. Dental maturity in Finnish children, estimated from the development of seven permanent mandibular teeth. *Acta Odontol Scand*, 1986; 44: 193-8.
82. Nalçacı R. Diş gelişimi ile yaş tahmini yöntemleri. *Gülhane Tıp Dergisi*, 1999; 145–158.
83. Kanchan T, Chugh V, Chugh A, ve ark. Age estimation using third molar maturation based on Demirjian's criteria. *Legal Medicine*, 2021; 53: 101959.
84. Mohammad N, Muad A, Ahmad R, ve ark. Accuracy of advanced deep learning with tensorflow and keras for classifying teeth developmental stages in digital panoramic imaging. *BMC Medical Imaging*, 2022; 22:
85. Willems G AS. Dental Age Estimation in Children and Adolescents. In: Franco A. A. WG, editor. *Forensic Odontology: Principles and Practice*: Wiley-Blackwell; 2019. p. 117–133
86. Koç A, Özlek E, Öner Talmaç AG. Accuracy of the London atlas, Willems, and Nolla methods for dental age estimation: a cross-sectional study on Eastern Turkish children. *Clin Oral Investig*, 2021; 25: 4833-4840.
87. Willems G, Van Olmen A, Spiessens B, ve ark. Dental age estimation in Belgian children: Demirjian's technique revisited. *J Forensic Sci*, 2001; 46: 893-5.
88. Ishwarkumar S, Pillay P, Chetty M, ve ark. The Application of the Cameriere's Methodologies for Dental Age Estimation in a Select KwaZulu-Natal Population of South Africa. *Dentistry Journal*, 2022; 10: 130.

89. Cameriere R, Ferrante L, Cingolani M. Age estimation in children by measurement of open apices in teeth. *Int J Legal Med*, 2006; 120: 49-52.
90. AlQahtani SJ, Hector MP, Liversidge HM. Brief communication: The London atlas of human tooth development and eruption. *American Journal of Physical Anthropology*, 2010; 142: 481-490.
91. Alkandiri F, Karimi A, Draft D, ve ark. Dental Age Estimation: A comparison of three methods of estimating dental age in a population of Kuwaiti children and adolescents. *Forensic Science International: Reports*, 2021; 3: 100214.
92. Kokomoto K, Kariya R, Muranaka A, ve ark. Automatic dental age calculation from panoramic radiographs using deep learning: a two-stage approach with object detection and image classification. *BMC Oral Health*, 2024; 24: 143.
93. Russell SJaN, Peter. *Artificial Intelligence: A Modern Approach*, 4th. Hoboken, NJ, Pearson, 2021.
94. McCarthy J, Minsky M, Rochester N, ve ark. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. *AI Magazine*, 2006; 27.
95. Williams JP. Book Reviews: STERNBERG, R. J. (1985). *Beyond IQ: A Triarchic Theory of Human Intelligence*. Cambridge, England: Cambridge University Press, Paperback, \$14.95, 411 pp. *Gift. Child Q.* 1987; 31: 46-47.
96. Pirim AGH. YAPAY ZEKA. *Yaşar Üniversitesi E-Dergisi*, 2006; 1: 81-93.
97. ÖNder HH. Uzaktan Eğitimde Bilgisayar Kullanımı ve Uzman Sistemler. *Türk. Online J. Educ. Technol.*, 2003; 2.
98. Arslan K. Eğitimde Yapay Zeka ve Uygulamaları. *Batı Anadolu Eğit. Bilim. Derg.*, 2020; 11: 71-88.
99. Goguen JA. L. A. Zadeh. Fuzzy sets. *Information and control*, vol. 8 (1965), pp. 338–353. - L. A. Zadeh. Similarity relations and fuzzy orderings. *Information sciences*, vol. 3 (1971), pp. 177–200. *J. Symb. Log.* 1973; 38: 656-657.
100. Alam T. *Genetic Algorithm: Reviews, Implementations, and Applications*, 2020.
101. Öztemel E. *Yapay sinir ağları*. PapatyaYayincilik, İstanbul, 2003.
102. Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 2018; 6: 25-36.
103. Akkoyun S, Yildiz N, Kaya H. Neural Network Estimation for Attenuation Coefficients for Gamma-Ray Angular Distribution. *Phys. Part. Nucl. Lett.* 2019; 16: 397-401.

104. Soffer S, Ben-Cohen A, Shimon O, ve ark. Convolutional Neural Networks for Radiologic Images: A Radiologist's Guide. Radiology, 2019; 290: 590-606.
105. Krogh A. What are artificial neural networks? Nat. Biotechnol. 2008; 26: 195-197.
106. Sinanoğlu C, Kurban AO, Yildirim S. Analysis of pressure variations on journal bearing system using artificial neural network. Ind. Lubr. Tribol., 2004; 56: 74-87.
107. Tok K. Hastalık teşhisi için bir yapay sinir ağları yazılımının tasarlanması ve gerçekleştirilmesi. Konya: Selçuk Üniversitesi 2017.
108. Yayık A, Kutlu Y. Yapay Sinir Ağları ile Kriptoloji Uygulamaları 2013.
109. Keskenler MF, Keskenler EF. Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. TiV, 2017; 5: 8-18.
110. Haykin S. Neural networks and learning machines, 3/E, Pearson Education India.
111. Kaynar O, Görmez Y, Yıldız M, ve ark. Makine Öğrenmesi Yöntemleri ile Duygu Analizi - Sentiment Analysis with Machine Learning Techniques, 2016.
112. Lange N. J. Am. Stat. Assoc. 1997; 92: 1642-1645.
113. Ozturk K, Şahin M. Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış-A General View of Artificial Neural Networks and Artificial Intelligence., 2018; 6: 25-36.
114. Chartrand G, Cheng PM, Vorontsov E, ve ark. Deep Learning: A Primer for Radiologists. Radiographics, 2017; 37: 2113-2131.
115. Erickson BJ, Korfiatis P, Akkus Z, ve ark. Machine Learning for Medical Imaging. RadioGraphics, 2017; 37: 505-515.
116. Goodfellow I, Bengio Y, Courville A, ve ark. Deep learning, MIT press Cambridge, 2016:
117. Wang S-C. Artificial Neural Network. 2003. p. 81-100.
118. Gürsakal N. Makine öğrenmesi ve derin öğrenme. Dora Basım Yayın Dağıtım, Bursa, 2017.
119. Sarker IH, Kayes ASM, Watters P. Effectiveness analysis of machine learning classification models for predicting personalized context-aware smartphone usage. J. Big Data., 2019; 6: 57.
120. Sarker IH. Machine Learning: Algorithms, Real-World Applications and Research Directions. SN Comput. Sci., 2021; 2: 160.
121. Montagnon E, Cerny M, Cadrin-Chênevert A, ve ark. Deep learning workflow in radiology: a primer. Insights into Imaging, 2020; 11: 22.
122. LeCun Y, Bengio Y, Hinton G. Deep Learning. Nature, 2015; 521: 436-44.

123. Janowczyk A, Madabhushi A. Deep learning for digital pathology image analysis: A comprehensive tutorial with selected use cases. *J. Pathol. Inform.*, 2016; 7: 29.
124. Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *Eur. Radiol. Exp.*, 2018; 2: 35.
125. Hao X, Zhang G, Ma S. Deep Learning. *Int. J. Semant. Comput.*, 2016; 10: 417-439.
126. Schulz H, Behnke S. Deep Learning. *KI - Künstliche Intelligenz*, 2012; 26.
127. Doğan F, Türkoğlu İ. Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DUJE*, 2019; 10: 409-445.
128. Fukushima K. Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural Netw.*, 1988; 1: 119-130.
129. Albawi S, Abed Mohammed T, Alzawi S. Understanding of a Convolutional Neural Network, 2017.
130. Girshick R, Donahue J, Darrell T, ve ark. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, 2013.
131. İnik Ö, Ülker E. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *GBAD*, 2017; 6: 85-104.
132. Hinton GE. A practical guide to training restricted Boltzmann machines, Berlin, Heidelberg, Springer, 2012: 599–619.
133. Serbest K, Aktürk S. Nesne Tespiti İçin Derin Öğrenme Kütüphanelerinin İncelenmesi. *Joinssr*, 2022; 3: 97-119.
134. Akın E, Şahin ME. Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. *EMO Bilimsel Dergi*, 2024; 14: 27-38.
135. Hochreiter S, Schmidhuber J. Long Short-Term Memory. *Neural Comput.*, 1997; 9: 1735-1780.
136. Shetty D, Varma J, Navi S, ve ark. Diving Deep into Deep Learning: History, Evolution, Types and Applications. *Int. J. Innov. Technol. Explor. Eng.*, 2020; Volume-9: 2278-3075.
137. Jaiswal P, Bhirud S. Study and Analysis of an Approach Towards the Classification of Tooth Wear in Dentistry Using Machine Learning Technique, 2021.
138. Lu X, Tsao Y, Matsuda S, ve ark., editors. Speech enhancement based on deep denoising autoencoder2013.

139. Bengio Y. Learning Deep Architectures for AI. Foundations, 2009; 2: 1-55.
140. Vincent P, Larochelle H, Bengio Y, ve ark. Extracting and composing robust features with denoising autoencoders, 2008.
141. Hinton GE, Osindero S, Teh YW. A fast learning algorithm for deep belief nets. Neural Comput., 2006; 18: 1527-54.
142. Litjens G, Kooi T, Bejnordi BE, ve ark. A survey on deep learning in medical image analysis. Med Image Anal, 2017; 42: 60-88.
143. Kim M, Yun J, Cho Y, ve ark. Deep Learning in Medical Imaging. Neurospine, 2019; 16: 657-668.
144. Ker J, Wang L, Rao J, ve ark. Deep Learning Applications in Medical Image Analysis. IEEE Access, 2018; 6: 9375-9389.
145. Redmon J, Farhadi A, editors. YOLO9000: better, faster, stronger. Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.; 2017.
146. Ekert T, Krois J, Meinhold L, ve ark. Deep Learning for the Radiographic Detection of Apical Lesions. J Endod, 2019; 45: 917-922.e5.
147. Lee J-H, Kim D-H, Jeong S-N, ve ark. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. J. Dent., 2018; 77: 106-111.
148. Bochkovskiy A, Wang C-Y, Liao H-y. YOLOv4: Optimal Speed and Accuracy of Object Detection, 2020.
149. Nickolls J, Dally WJ. The GPU Computing Era. IEEE Micro, 2010; 30: 56-69.
150. Kim C, Kim D, Jeong H, ve ark. Automatic Tooth Detection and Numbering Using a Combination of a CNN and Heuristic Algorithm. Appl. Sci., 2020; 10: 5624.
151. Kumar A, Srivastava S. Object Detection System Based on Convolution Neural Networks Using Single Shot Multi-Box Detector. Procedia Comput. Sci. 2020; 171: 2610-2617.
152. Demir Ö, Çalışkan D. Derin Öğrenme Yöntemleri İle Şüpheli Davranış Tespiti. Int. J. Appl. Eng. Technol., 2022; 3: 28-43.
153. Girshick R, Donahue J, Darrell T, ve ark., editors. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. 2014 Proc. Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.; 2014 23-28 June 2014.
154. Redmon J, Divvala S, Girshick R, ve ark., editors. You Only Look Once: Unified, Real-Time Object Detection. Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.; 2016 27-30 June 2016.

155. Girshick R. Fast r-cnn., 2015.
156. Gkioxari G, Girshick R, Malik J, editors. Contextual action recognition with r* cnn. Proc. IEEE Int. Conf. Comput. Vis.; 2015.
157. Jiang H, Learned-Miller E, editors. Face Detection with the Faster R-CNN. Proc. IEEE Int. Conf. Autom. Face Gesture Recognit.; 2017 30 May-3 June 2017.
158. Liu W, Erhan D, Szegedy C, ve ark. SSD: Single Shot MultiBox Detector, 2016.
159. Redmon J, Farhadi A. Yolov3: An incremental improvement. arXiv preprint arXiv:180402767, 2018.
160. Xu R, Lin H, Lu K, ve ark. A Forest Fire Detection System Based on Ensemble Learning. Forests, 2021; 12: 217.
161. Yung NDT, Wong WK, Juwono FH, ve ark., editors. Safety Helmet Detection Using Deep Learning: Implementation and Comparative Study Using YOLOv5, YOLOv6, and YOLOv7. GECOST 2022; 2022 26-28 Oct. 2022.
162. Wang C-Y, Bochkovskiy A, Liao H-y. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors, 2022.
163. Cao L, Zheng X, Fang L. The Semantic Segmentation of Standing Tree Images Based on the Yolo V7 Deep Learning Algorithm. Electronics, 2023; 12: 929.
164. Terven J, Cordova-Esparza D-M. A Comprehensive Review of YOLO: From YOLOv1 to YOLOv8 and Beyond, 2023.
165. Ultralytics. YOLO by Ultralytics Documentation. <https://docs.ultralytics.com>. 21 Nisan 2025.
166. Team Y. YOLOv9: Next Generation Object Detector. <https://arxiv.org/abs/2402.13616>. 21 Nisan 2025.
167. Wang A, Chen H, Liu L, ve ark. Yolov10: Real-time end-to-end object detection. Adv Neural Inf Process Syst, 2024; 37: 107984-108011.
168. Ultralytics.YOLOv11 Teknik Dokümantasyonu. <https://docs.ultralytics.com/models/yolo11>. 21 Nisan 2024.
169. Gündüz Mengübaşı G, Cedimoglu I. Derin Öğrenme Algoritmalarını Kullanarak Görüntüden Cinsiyet Tahmini. Sak Univ J Comput Inf Sci, 2019; 2: 9-17.
170. Tan FG, Yüksel AS, Aydemir E, ve ark. Derin Öğrenme Teknikleri İle Nesne Tespiti Ve Takibi Üzerine Bir İnceleme. Eur J Sci Technol, 2021; 159-171.
171. Toğaçar M, Ergen B. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. Fırat Univ J Eng Sci, 2019; 31: 109-121.

172. Jia Y, Shelhamer E, Donahue J, ve ark. Caff : Convolutional Architecture for Fast Feature Embedding. Proc ACM Conf Multimedia (MM), 2014.
173. Chen T, Li M, Li Y, ve ark. MXNet: A Flexible and Efficient Machine Learning Library for Heterogeneous Distributed Systems., 2015.
174. Buyuk C. Diř Hekimlięinde Yapay Zeka. 2020. p. 233-256.
175. Ding H, Wu J, Zhao W, ve ark. Artificial intelligence in dentistry—A review. Front Dent Med, 2023; 4: 1085251.
176. Rischke R, Schneider L, M ller K, ve ark. Federated Learning in Dentistry: Chances and Challenges. J Dent Res, 2022; 101: 1269-1273.
177. Katne T, Kanaparthi A, Goud ds, ve ark. Artificial Intelligence: Demystifying Dentistry – The Future and Beyond. Int J Contemp Med Surg Radiol, 2019; 4:
178. Miki Y, Muramatsu C, Hayashi T, ve ark. Classification of teeth in cone-beam CT using deep convolutional neural network. Comput Biol Med, 2017; 80: 24-29.
179. Suzuki K. Overview of deep learning in medical imaging. Radiol Phys Technol, 2017; 10: 257-273.
180. Vishwanathaiah S, Fageeh HN, Khanagar SB, ve ark. Artificial Intelligence Its Uses and Application in Pediatric Dentistry: A Review. Biomedicines, 2023;11.
181. Puttagunta M, Ravi S. Medical image analysis based on deep learning approach. Multimed Tools Appl, 2021; 80: 24365-24398.
182. Srivastava N, Hinton G, Krizhevsky A, ve ark. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. J Mach Learn Res, 2014; 15: 1929-1958.
183.  zkesici MY, Yılmaz S. Oral Ve Maksillofasiyal Radyoloji’de Yapay Zeka. Saęlık Bilim Derg, 2021; 30: 346-351.
184. Buderer NM. Statistical methodology: I. Incorporating the prevalence of disease into the sample size calculation for sensitivity and specificity. Acad Emerg Med 1996; 3: 895-900. DOI: 10.1111/j.1553-2712.1996.tb03538.x.
185. Parlak Baydoęan M, Cořgun Baybars S and Arslan Tuncer S. Age Detection by Deep Learning from Dental Panoramic Radiographs. Artificial Intelligence Theory and Applications 2022; 2: 51-58.
186. Kılıç B,  ner Y. Yargıtay kararlarının suç t rlerine g re makine  ęrenmesi y ntemleri ile sınıflandırılması. *Avrasya Sosyal ve Ekonomi Arařtırmaları Dergisi*, 2022; 9(6): 143–157.
187. Lee KS, Kwak HJ, Oh JM, ve ark. Automated Detection of TMJ Osteoarthritis Based on Artificial Intelligence. J Dent Res, 2020; 99: 1363-1367.

188. He K, Gkioxari G, Dollar P, ve ark. Mask R-CNN, 2017.
189. Badrov J, Lauc T, Nakaš E, ve ark. Dental Age and Tooth Development in Orthodontic Patients with Agenesis of Permanent Teeth. *Biomed Res Int*, 2017; 2017: 8683970.
190. Gaethofs M, Verdonck A, Carels C, ve ark. Delayed dental age in boys with constitutionally delayed puberty. *Eur J Orthod*, 1999; 21: 711-5.
191. Jayaraman J, Wong HM, King NM, ve ark. The French–Canadian data set of Demirjian for dental age estimation: A systematic review and meta-analysis. *J Forensic Leg Med*, 2013; 20: 373-381.
192. Karadayi B, İşcan M. Dental Age Estimation with Demirjian Technique on Living Children in Northwestern Turkey. *Turk Klin J Forensic Med*, 2014; 11: 71-77.
193. Karataş O, Öztürk F, Dedeoğlu N, ve ark. Dental age assessment: The applicability of Demirjian method in southwestern of eastern Anatolia region Turkish children. *Cumhur Dent J*, 2012; 15: 130-137.
194. De Donno A, Angrisani C, Mele F, ve ark. Dental age estimation: Demirjian's versus the other methods in different populations. A literature review. *Med Sci Law*, 2021; 61: 125-129.
195. Wang J, Bai X, Wang M, ve ark. Applicability and accuracy of Demirjian and Willems methods in a population of Eastern Chinese subadults. *Forensic Sci Int*, 2018; 292: 90-96.
196. Carelli J, da Silva GS, Gomes MV, ve ark. Demirjian's and Cameriere's Methods for the Assessment of Dental Age Estimation in Children from a Southern Brazilian City. *Diagnostics*, 2024; 14: 1513.
197. Moca AE, Ciavoi G, Todor BI, ve ark. Validity of the Demirjian Method for Dental Age Estimation in Romanian Children. *Children*, 2022; 9: 567.
198. Esan TA, Yengopal V, Schepartz LA. The Demirjian versus the Willems method for dental age estimation in different populations: A meta-analysis of published studies. *PLoS One*, 2017; 12: e0186682.
199. Hostiuc S, Edison SE, Diaconescu I, ve ark. Accuracy of the Demirjian's method for assessing the age in children, from 1973 to 2020. A meta-analysis. *Leg Med* , 2021; 52: 101901.
200. Galibourg A, Cussat-Blanc S, Dumoncel J, ve ark. Comparison of different machine learning approaches to predict dental age using Demirjian's staging approach. *Int J Legal Med*, 2021; 135: 665-675.

201. Milošević D, Vodanovic M, Galic I, ve ark. Automated estimation of chronological age from panoramic dental X-ray images using deep learning. *Expert Syst Appl*, 2021; 189: 116038.
202. Guo YC, Han M, Chi Y, ve ark. Accurate age classification using manual method and deep convolutional neural network based on orthopantomogram images. *Int J Legal Med*, 2021; 135: 1589-1597.
203. Izzetti R, Nisi M, Aringhieri G, ve ark. Basic Knowledge and New Advances in Panoramic Radiography Imaging Techniques: A Narrative Review on What Dentists and Radiologists Should Know. *Appl Sci*, 2021; 11: 7858.
204. Saric R, Kevric J, Hadziabdic N, ve ark. Dental age assessment based on CBCT images using machine learning algorithms. *Forensic Sci Int*, 2022; 334: 111245.
205. Kurt A, Günaçar DN, Şılbır FY, ve ark. Evaluation of tooth development stages with deep learning-based artificial intelligence algorithm. *BMC Oral Health*, 2024; 24: 1034.
206. Roh B-Y, Lee J-S, Lim S-B, ve ark. Dental Age Estimation Using the Demirjian Method: Statistical Analysis Using Neural Networks. *Korean J Leg Med*, 2023; 47: 1-7.
207. Sakaryalı D, Pınar Ö NP, Betül MÖ. Diş Gelişiminin Belirlenmesinde Demirjian Ve Moorrees Yöntemleri Kullanılarak İki Farklı Araştırmacı Arasındaki Uyumun Değerlendirilmesi. *Atatürk Univ Dis Hekim Fak Derg*, 2021; 31: 202-206.
208. Yavuz BS, Ekmekcioglu O, Ankarali H. Comparison of different dental age estimation methods with deep learning: Willems, Cameriere-European, London Atlas. *Int J Legal Med*, 2025.
209. Ong S-H, Kim H, Song J-S, ve ark. Fully automated deep learning approach to dental development assessment in panoramic radiographs. *BMC Oral Health*, 2024; 24: 426.
210. Wallraff S, Vesal S, Syben C, ve ark. Age Estimation on Panoramic Dental X-ray Images using Deep Learning. 2021. p. 186-191.
211. Wu TJ, Ling Tsai C, Huang YH, ve ark. Efficacy of machine learning assisted dental age assessment in local population. *Leg Med*, 2022; 59: 102148.
212. Oliveira W, Albuquerque Santos M, Burgardt CAP, ve ark. Estimation of human age using machine learning on panoramic radiographs for Brazilian patients. *Sci Rep.*, 2024; 14: 19689.

EKLER

EK-1 Öz Geçmiş

Kişisel Bilgiler	
Adı Soyadı	Sude GÜMÜŞ
Cinsiyet	Kadın
Eğitim	
Lise	Korkmaz Yiğit Anadolu Lisesi (2014)
Lisans	İstanbul Üniversitesi Diş Hekimliği Fakültesi (2015-2020)
Uzmanlık	Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Ana Bilim Dalı (2022-2025)
Yabancı Dil	
İngilizce	Orta

EK-2 Etik Kurul Onay Formu



T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığı



Sayı : E-40465587-050.01.04-862
Konu : Etik Kurul

30.10.2023

Sayın Dr. Öğr. Üyesi Ayça KURT

Üniversitemiz Girişimsel Olmayan Klinik Araştırmalar Etik Kuruluna yapmış olduğunuz “Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zeka Uygulamaları Aracılığıyla Panoramik Radyografiden Diş Yaşının Tespiti İle Demirjian Diş Yaşı Belirleme Yönteminin Kıyaslanması” isimli başvurunuz etik kurulumuz yönergesine göre 26.10.2023 tarihinde yapmış olduğu toplantıda incelenmiş olup, 2023/250 karar numarası ile bilimsel ve etik yönden uygun bulunmuştur.

Bilgilerinizi ve gereğini saygılarımla rica ederim.

Doç. Dr. Tahsin Gökhan TELATAR
Başkan

Bu belge güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : 9174fee9a709

Belge Takip Adresi: <http://ebys.erdogan.edu.tr/EBYS/eimzadogrulama>

Fener Mah. Zihni Derin Yerleşkesi 53100 Rize / TÜRKİYE
Telefon No : +90 (464) 223 61 26 Faks No : +90 (464) 223 53 76
e-Posta : [Internet Adresi: http://www.erdogan.edu.tr/](http://www.erdogan.edu.tr/)
Kep Adresi:

Bilgi için : BURAK HANKAYA
Bilgisayar İşletmen



EK-3 Dekanlık İzin Belgesi



T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
Dış Hekimliği Fakültesi Dekanlığı



Sayı : E-61245112-302.08-9695
Konu : Bilimsel Çalışma İzni (Dr. Öğr. Üyesi
Ayça KURT)

29.02.2024

Sayın Dr. Öğr. Üyesi Ayça KURT

İlgi : 28.02.2024 tarihli ve sayılı yazı.

"Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zeka Uygulamaları Aracılığıyla Diagnostik Doğruluğun Tespiti" isimli bilimsel çalışma ile ilgili izin talebiniz 6698 sayılı "Kişisel Verilerin Korunması Kanunu" ilgili yönetmelikler ve Hasta Hakları Yönetmeliği'nin "Tıbbi Araştırmalarda Rıza" başlıklı 32. maddesinde yer alan hükümlere riayet edilmesi şartıyla Dekanlığımız tarafından uygun görülmüştür.

Bilgilerinizi ve gereğini rica ederim.

Prof. Dr. Zeynep YEŞİL
Dekan

Bu belge güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : 61041d2e9e9e

Belge Takiye Adresi: <http://ehys.erdogan.edu.tr/EBYS/eimzadogrulama>

İslampazarı Mahallesi Menderes Bulvarı No:612 Merkez/RİZE / TÜRKİYE
Telefon No :+90 (464) 214 22 65, +90 (464)214 21 81 Faks No :+90 (464)
222 00 02
e-Posta : dis@erdogan.edu.tr İnternet Adresi: <http://www.erdogan.edu.tr/>
Kep Adresi: erdogan@hs01.kep.tr

Bilgi için : ŞAFAK DEMİRCİ
Memu
Dahili: 532



EK-4 İntihal Raporu

Sude Tez 22.05.2025.docx

ORJİNALLİK RAPORU

% 7	% 6	% 5	% 2
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	acikbilim.yok.gov.tr İnternet Kaynağı	% 1
2	docplayer.biz.tr İnternet Kaynağı	% 1
3	dergipark.org.tr İnternet Kaynağı	<% 1
4	openaccess.hacettepe.edu.tr:8080 İnternet Kaynağı	<% 1
5	nek.istanbul.edu.tr:4444 İnternet Kaynağı	<% 1
6	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	<% 1
7	search.trdizin.gov.tr İnternet Kaynağı	<% 1
8	www.researchgate.net İnternet Kaynağı	<% 1
9	core.ac.uk İnternet Kaynağı	<% 1