

T.C

AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ PEDODONTİ ANABİLİM DALI

DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ
YAPAY ZEKÂ ALGORİTMALARIYLA PANORAMİK
RADYOGRAFİLERDE DENS İNVAGİNATUS TESPİTİ

Hazırlayan

Esra Nur AKGÜL

Danışman

Doç. Dr. Burcu GÜÇYETMEZ TOPAL

2024 – AFYONKARAHİSAR

T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ PEDODONTİ ANABİLİM DALI

DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ
YAPAY ZEKÂ ALGORİTMALARIYLA PANORAMİK
RADYOGRAFİLERDE DENS İNVAGİNATUS TESPİTİ

Hazırlayan

Arş. Gör. Dt. Esra Nur AKGÜL

DİŞ HEKİMLİĞİNDE UZMANLIK TEZİ

Danışman

Doç. Dr. Burcu GÜÇYETMEZ TOPAL

Bu çalışma Afyonkarahisar Sağlık Bilimleri Üniversitesi Bilimsel Araştırma
Projeleri Birimi tarafından 24.DUS.001 kodlu proje ile desteklenmiştir.

2024-AFYONKARAHİSAR

BİLİMSEL ETİĞE UYGUNLUK SAYFASI

Çalışmamızın etik kurul onayı Afyonkarahisar Sağlık Bilimleri Üniversitesi Klinik Araştırmalar Etik Kurul Başkanlığı'ndan alınmıştır (10.10.2023 tarihli 2023/448 sayılı karar). (EK-1)



TEŞEKKÜR

Uzmanlık eğitimim süresince akademik bilgi ve klinik tecrübelerini paylaşarak her daim yol gösteren, tezimin her aşamasında desteğini ve emeğini esirgemeyen, anlayış ve hoşgörüsü ile desteğini her zaman hissettiğim değerli tez danışman hocam Doç.Dr. Burcu GÜÇYETMEZ TOPAL'a,

Uzmanlık eğitimim boyunca bilgi ve tecrübelerini paylaşan, yardımlarını esirgemeyen ve eğitimimde önemli katkıları olan değerli hocalarım Dr. Öğr. Üyesi Özgür DOĞAN, Dr. Öğr. Üyesi Mehmet ÜNAL, Dr. Öğr. Üyesi İsmail Haktan ÇELİK ve Dr. Öğr. Üyesi Hatice TÜRKOĞLU'na,

Tez çalışmamıza bilgi ve tecrübeleriyle desteği ve çalışmamızın yapay zekâ prosedürlerinin gerçekleşmesindeki katkı ve emeklerinden dolayı Doç. Dr. Elif BİLGİR ve ekibine,

Eğitimim boyunca birlikte çalışmaktan mutluluk duyduğum, her zaman desteklerini hissettiğim değerli asistan arkadaşlarım Esra AKÇAY, Esmâ ATIŞ, Sümeyye Tuğçe KURAL, Melikşah URAL ve Pedodonti Anabilim Dalı'ndaki tüm asistan arkadaşlarıma ve yardımcı sağlık personeline,

Üniversite ve uzmanlık eğitimim boyunca her zaman yanımda olan ve beni destekleyen arkadaşlarım Ceren KILINÇARSLAN, Ayşenur YAZIM, Şeyma KÖLE ve Fatma YAŞAR'a,

Beni bu günlere getiren, hayatım boyunca destek ve sevgileriyle her daim yanımda yer alan annem Filiz AKGÜL, babam Yusuf AKGÜL, kardeşlerim Ahmet Fatih AKGÜL ve Zeynep AKGÜL'e

Sonsuz teşekkürlerimi sunarım.

DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKÂ ALGORİTMALARIYLA PANORAMİK RADYOGRAFİLERDE DENS İNVAGİNATUS TESPİTİ

Esra Nur AKGÜL

Afyonkarahisar Sağlık Bilimleri Üniversitesi Diş Hekimliği Fakültesi
Pedodonti Anabilim Dalı Diş Hekimliğinde Uzmanlık Tezi

Ekim 2024

Danışman: Doç. Dr. Burcu GÜÇYETMEZ TOPAL

ÖZET

Amaç: Çalışmamızın amacı, panoramik radyografilerde dens invaginatuslu dişlerin tespitinde, iki farklı etiketleme ile YOLOv5 ve YOLOv8 derin öğrenme modelleri kullanılarak geliştirilen yapay zekâ uygulamasının başarısını ve güvenilirliğini değerlendirmektir.

Gereç ve Yöntem: Bu çalışmada, 8-18 yaş arası hastalara ait 656 panoramik radyografi üzerinde üst anterior bölgedeki dens invaginatuslu dişlerin detection ve segmentasyon yöntemleri ile etiketlemesi yapıldı. Görüntüler üzerindeki etiketlemeler, CranioCatch (Eskişehir, Türkiye) yazılımı kullanılarak 2,5 yıllık deneyime sahip araştırma görevlisi ve 15 yıllık deneyime sahip çocuk diş hekimi uzmanı tarafından gerçekleştirildi. Her bir model kesinlik, duyarlılık ve F1 skorunu içeren performans kriterlerine göre değerlendirildi.

Bulgular: YOLOv5 modelinin detection yöntemi ile etiketlemeler sonucu kesinlik, duyarlılık ve F1 skoru değerleri sırasıyla 0,945, 0,887 ve 0,915 iken; segmentasyon yöntemi için bu değerler 0,905, 0,928, 0,916 olarak bulundu. YOLOv8 modelinin detection yöntemi ile etiketlemeler sonucu kesinlik, duyarlılık ve F1 skoru sırasıyla 0,950, 1 ve 0,974 iken; segmentasyon yöntemi için bu değerler 0,940, 0,994, 0,966 olarak bulundu.

Sonuç: Çalışmamızın sonuçlarına göre geliştirilen derin öğrenme modellerinin, dens invaginatus tespitinde başarılı olduğu görülmüştür. Derin öğrenme destekli sistemlerin çocuk diş hekimliği pratiğinde yer alabileceği ve hekimler için karar destek mekanizması olabileceği düşünülmektedir.

Anahtar Kelimeler: Dens invaginatus, Panoramik radyografi, Yapay zekâ, YOLO

DETECTION OF DENS INVAGINATUS IN PANORAMIC RADIOGRAPHS WITH ARTIFICIAL INTELLIGENCE ALGORITHMS DEVELOPED WITH DEEP LEARNING METHOD

Esra Nur AKGÜL

**Afyonkarahisar Health Sciences University Faculty of Dentistry
Department of Pediatric Dentistry Specialization Thesis**

October 2024

Supervisor: Assoc.Prof. Burcu GÜÇYETMEZ TOPAL

ABSTRACT

Objective: The aim of this study was to evaluate the success and reliability of an artificial intelligence application developed using YOLOv5 and YOLOv8 deep learning models with two different labeling for the detection of teeth with dens invaginatus in panoramic radiographs.

Materials and Methods: In this study, 656 panoramic radiographs of patients aged 8 to 18 were labeled for teeth with dens invaginatus in the upper anterior region using segmentation and detection methods. The labeling of the images was performed using the CranioCatch software (Eskişehir, Turkey) by a research assistant with 2.5 years of experience and a pediatric dentist with 15 years of experience. Each model was evaluated based on performance criteria, including precision, accuracy, and F1 score.

Results: In this study, the detection method of the YOLOv5 model yielded precision, recall, and F1 scores of 0.945, 0.887, and 0.915, respectively. For the segmentation method of the same model, these values were 0.905, 0.928, and 0.916, respectively. In the case of the YOLOv8 model, the detection method achieved precision, recall, and F1 scores of 0.950, 1, and 0.974 while for the segmentation method, these values were 0.940, 0.994, and 0.966, respectively.

Conclusion: Based on the results of this study, it has been observed that the deep learning models developed were successful in detecting dens invaginatus. It is believed that deep learning-supported systems could be integrated into pediatric dentistry practice and serve as a decision support mechanism for clinicians.

Keywords: Dens invaginatus, Panoramic radiography, Artificial intelligence, YOLO

KISALTMALAR VE SİMGELER DİZİNİ

ANN	Yapay Sinir Ağları (Artificial Neural Network)
AUC	Eğri Altında Kalan Alan (Area Under Curve)
CNN/ESA	Evrışimli Sinir Ağı (Convolutional Neural Network)
DN	Doğru Negatif
DP	Doğru Pozitif
IBM	International Business Machines
IoU	Birleşim Üzerinden Ortalama Kesişim (Intersection Over Union)
KIBT	Konik Işınlı Bilgisayarlı Tomografi
kVp	Kilovolt Peak
LSTM	Uzun-Kısa Süreli Bellek Ağları (Long Short-Term Memory)
mA	Miliamper
mAP	Ortalama Kesinlik Değerlerinin Ortalaması (Mean Average Precision)
PR	Precision-Recall (Kesinlik-Duyarlılık)
RBM	Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine)
R-CNN	Bölge Tabanlı CNN (Region-based Convolutional Neural Network)
RNN	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
ROC	Alıcı İşlem Karakteristiği (Receiver Operating Characteristic)
YN	Yanlış Negatif
YOLO	You Only Look Once
YP	Yanlış Pozitif

TABLolar DİZİNİ

Tablo 2.1: Dens invaginatus prevalansı üzerine yapılan çalışmalar

Tablo 2.2: Çocuk diş hekimliğinde yapay zekâ uygulamaları ile ilgili bazı çalışmalar

Tablo 3.1: Veri setlerinin sınıflandırılması

Tablo 4.1: YOLOv5 modelinin detection ve segmentasyon için DP, YP ve YN değerleri

Tablo 4.2: YOLOv5 modelinin detection ve segmentasyon için duyarlılık, kesinlik ve F1 skorları

Tablo 4.3: YOLOv8 modelinin detection ve segmentasyon için DP, YP ve YN değerleri

Tablo 4.4: YOLOv8 modelinin detection ve segmentasyon için duyarlılık, kesinlik ve F1 skorları

ŞEKİLLER DİZİNİ

Şekil 2.1: Oehler's sınıflaması

Şekil 2.2: Dens invaginatusun klinik görüntüsü

Şekil 2.3: Dens invaginatusun iki boyutlu radyografik görüntüsü

Şekil 2.4 Turing Testi

Şekil 2.5: Yapay zekânın tarihsel gelişimi

Şekil 2.6: Yapay zekâ ve temel kavramlar arasındaki ilişki

Şekil 2.7: Biyolojik nöronun yapısı

Şekil 2.8: Yapay nöronun yapısı

Şekil 2.9: Tek katmanlı algılayıcı modelinin yapısı

Şekil 2.10: Çok katmanlı yapay sinir ağının genel yapısı

Şekil 2.11: İleri ve geri beslemeli ağ yapısı örnekleri

Şekil 2.12: CNN katmanları

Şekil 2.13: Tekrarlayan sinir ağı yapısının modeli

Şekil 2.14: Uzun-kısa süreli bellek ağlarının yapısı

Şekil 2.15: Kısıtlı Boltzman Makinesi

Şekil 2.16: Derin oto-kodlayıcı yapısı

Şekil 2.17: YOLO nesne tespit aşamaları

Şekil 3.1: Çalışmamıza dahil edilen bir hastanın 11,12,21 ve 22 numaralı dişlerinin klinik ve radyografik görünümü

Şekil 3.2: CranioCatch uygulamasında panoramik röntgen üzerinde yapılan etiketlemeler

Şekil 3.3: Dens invaginatuslu dişlerde poligon yöntemi ile invajinasyon alanının etiketlenmesi

Şekil 3.4: Dens invaginatus bulunan dişlerin kronlarının etiketlenmesi

Şekil 3.5: Gerçekleştirilen dens invaginatus tespit modelinin gelişim aşamalarının akış diyagramı

Şekil 3.6: Karışıklık matrisi

Şekil 4.1: YOLOv5 modeline ait karışıklık matrisi

Şekil 4.2: YOLOv5 modeline ait dens invaginatus tespiti için ROC eğrisi

Şekil 4.3: YOLOv5 modelinin dens invaginatus tespiti için Kesinlik-Duyarlılık (Precision-Recall) eğrisi

Şekil 4.4: YOLOv5 modelinin 12 ve 22 numaralı dişlerdeki dens invaginatus için doğru pozitif tespiti

Şekil 4.5: YOLOv5 modelinin 11 ve 21 numaralı dişler için yanlış pozitif tespiti

Şekil 4.6: YOLOv5 modelinin 11 ve 21 numaralı dişler için yanlış negatif tespiti

Şekil 4.7: YOLOv8 modeline ait karışıklık matrisi

Şekil 4.8: YOLOv8 modeline ait dens invaginatus tespiti için ROC eğrisi

Şekil 4.9: YOLOv8 modelinin dens invaginatus tespiti için Kesinlik-Duyarlılık (Precision-Recall) eğrisi

Şekil 4.10: YOLOv8 modelinin 12 ve 22 numaralı dişlerdeki dens invaginatus için doğru pozitif tespiti

Şekil 4.11: YOLOv8 modelinin 23 numaralı dişteki yanlış pozitif tahmini

Şekil 4.12: YOLOv8 modelinin 11 ve 22 numaralı dişler için yanlış negatif tespiti

İÇİNDEKİLER

İÇ KAPAK.....	i
BİLİMSEL ETİĞE UYGUNLUK SAYFASI.....	ii
TEŞEKKÜR	iii
ÖZET.....	iv
ABSTRACT	v
KISALTMALAR VE SİMGELER DİZİNİ.....	vi
TABLolar DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
1. GİRİŞ VE AMAÇ.....	1
2. GENEL BİLGİLER.....	3
2.1. Dental Anomaliler	3
2.1.1. Durum Anomalileri	4
2.1.2. Sayı Anomalileri	4
2.1.2.1. Hiperdonti	4
2.1.2.2. Hipodonti	5
2.1.3. Boyut Anomalileri.....	5
2.1.3.1. Makrodonti	5
2.1.3.2. Mikrodonti	5
2.1.4. Yapı (Doku) Anomalileri.....	6
2.1.4.1. Amelogenezis İmperfekta.....	6
2.1.4.2. Dentinogenezis İmperfekta	7
2.1.4.3. Dentin Displazisi	7
2.1.4.4. Rejyonel Odontodisplazi	8
2.1.5. Biçim (Şekil) Anomalileri.....	8
2.1.5.1. Füzyon.....	8
2.1.5.2. Geminasyon	9
2.1.5.3. Konkresens	9
2.1.5.4. Dilaserasyon.....	9
2.1.5.5. Taurodontizm	9
2.1.5.6. Dens Evaginatus.....	10
2.2. Dens İnvaginatus	10
2.2.1. Dens İnvaginatusun Etiyolojisi.....	11
2.2.3. Dens İnvaginatusun Sınıflandırılması.....	11

2.2.4. Dens İnvaginatusun Prevalansı.....	13
2.2.5. Dens İnvaginatusun Klinik Deęerlendirmesi.....	15
2.2.6. Dens İnvaginatusun Radyografik Deęerlendirmesi.....	17
2.2.7. Dens İnvaginatuslu Diřlerin Histolojisi.....	19
2.2.8. Dens İnvaginatuslu Diřlerde Tedavi Planlaması.....	19
2.2.8.1. Oehlers Tip I Dens İnvaginatusun Tedavisi.....	20
2.2.8.2. Oehlers Tip II Dens İnvaginatusun Tedavisi.....	20
2.2.8.3. Oehlers Tip III Dens İnvaginatusun Tedavisi.....	21
2.3. Yapay Zekâ Nedir?.....	22
2.3.1. Yapay Zekânın Tarihsel Geliřimi.....	23
2.4. Makine Öğrenimi.....	25
2.4.1. Makine Öğreniminin Sınıflandırılması.....	26
2.4.1.1. Denetimli Öğrenme.....	26
2.4.1.2. Denetimsiz Öğrenme.....	27
2.4.1.3. Takviyeli (Pekiřtirmeli) Öğrenme.....	27
2.5. Yapay Sinir Ağları.....	27
2.5.1. Tek Katmanlı Algılayıcılar.....	29
2.5.2. Çok Katmanlı Algılayıcılar.....	29
2.5.3. İleri Beslemeli Yapay Sinir Ağları.....	30
2.5.4. Geri Beslemeli Yapay Sinir Ağları.....	30
2.6. Derin Öğrenme.....	31
2.7. Derin Öğrenme Mimarileri.....	31
2.7.1. Evriřimli (Konvolüsyonel) Sinir Ağları (CNN).....	31
2.7.2. Tekrarlayan Sinir Aęı (RNN-Recurrent Neural Network).....	32
2.7.3. Uzun-Kısa Süreli Bellek Ağları (LSTM- Long Short-Term Memory).....	33
2.7.4. Kısıtlı Boltzmann Makinesi (RBM-Restricted Boltzmann Machine).....	34
2.7.5. Derin İnanç Ağları (DBN-Deep Belief Network).....	34
2.7.6. Derin Oto-Kodlayıcılar (Deep Auto Encoder).....	35
2.8. Derin Öğrenme Modelleri.....	35
2.8.1. LeNet.....	35
2.8.2. AlexNet.....	36
2.8.3. VGG Net.....	36
2.8.4. Google Net.....	36
2.8.5. ResNet.....	36

2.8.6. YOLO	37
2.9. Derin Öğrenme Kütüphaneleri	38
2.9.1. Caffe2.....	38
2.9.2. TensorFlow	38
2.9.3. Torch	38
2.9.4. Theano	38
2.9.5. Keras	39
2.9.6. PyTorch.....	39
2.10. Diş Hekimliğinde Yapay Zekâ.....	39
2.11. Çocuk Diş Hekimliğinde Yapay Zekâ	40
3. GEREÇ VE YÖNTEM	44
3.1. Görüntülerin Seçilmesi.....	44
3.2. Panoramik Radyografi Veri Setinin Elde Edilmesi	45
3.3. Görüntü Değerlendirilmesi ve Etiketleme.....	45
3.4. Derin Öğrenme Mimarisi ve Model Geliştirilmesi	47
3.5. Eğitim Aşaması.....	47
3.6. İstatiksel Analiz	49
3.6.1. Karışıklık Matrisi Hesaplama Prosedürü.....	49
3.7. Performans Değerlendirmesi	50
3.8. Alıcı İşlem Karakteristiği (AİK-ROC)	51
3.9. Kesinlik- Duyarlılık Eğrisi (PR Eğrisi, Precision-Recall Curve).....	51
4. BULGULAR.....	52
5. TARTIŞMA.....	61
6. SONUÇ VE ÖNERİLER.....	75
7. KAYNAKLAR.....	76
EKLER.....	89

DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKÂ ALGORİTMALARIYLA PANORAMİK RADYOGRAFİLERDE DENS İNVAGİNATUS TESPİTİ

1. GİRİŞ VE AMAÇ

Dental anomalilerin biçim (şekil) bozukluklarından olan dens invaginatus, odontogenez sırasında mine organının dental papilla içine invajinasyonundan kaynaklanan gelişimsel bir dental anomalidir (1). Dens invaginatus etkilenen dişlerin klinik ve radyografik görünümleri değişkenlik göstermekte olup bu dişler genellikle rutin muayene sırasında tesadüfen tespit edilmektedir. Dens invaginatus radyografik olarak, genellikle dişin kronuyla sınırlı veya köke uzanan radyopak mine ile çevrili radyolüsent bir invajinasyon şeklinde izlenir. İnvajinasyon, ağız ortamı ile bağlantılı olduğu için gıda artıkları ve mikroorganizmalar için retansiyon alanı oluşturur (2). İnvajinasyon bölgesinde minenin bulunmadığı veya çürük nedeniyle kaybolduğu durumlarda, mikroorganizmalar dentin tübülleri yoluyla pulpaya ulaşabilmekte, pulpa nekrozu ve ardından periapikal patolojiye neden olabilmektedir. Dens invaginatuslu dişlerin anatomik karmaşıklığı nedeniyle endodontik tedavi son derece zor olabilmekte ve özellikle çocuk hastalar çoğu zaman endodontik tedaviyi tolere etmekte zorlanmaktadır (3,4). Dolayısıyla, profilaktik tedavi ile yönetilebilecek dens invaginatusun erken teşhisi hem klinisyenler hem de hastalar için zaman ve kooperasyon açısından oldukça önem arz etmektedir.

Son yıllarda sağlık alanında yapay zekâ ve özellikle derin öğrenme algoritmaları, hastalık riskinin tahmin edilmesi, hastalıkların teşhisi ve prognozunun değerlendirilmesi, anomali ve patolojilerin tespiti, anatomik yapıların incelenmesi gibi konularda önemli ilerlemeler kaydetmiş olup büyük bir ilgi görmektedir (5). Özellikle diş hekimliği alanında kullanılan yapay zekâ algoritmaları hem zaman açısından verimliliği artırmakta hem de diş hekimlerinin teşhis koyma süreçlerine katkıda bulunmaktadır (6).

Çocuk diş hekimliğinde yapay zekâ uygulamaları; süt ve daimi dişlerin tespiti, çürük tespiti, plak tespiti, yaş tahmini, dental anomali tespiti, anatomik alanların tespiti gibi konulara odaklanmıştır (7). Dens invaginatus tespiti ile ilgili ise erişilebilir literatürdeki yayın sayısı oldukça az olup, özellikle çocuk ve adölesan hastalarda yürütülen ve iki farklı etiketleme yöntemini karşılaştıran bir çalışmaya rastlanmamıştır.

Çalışmamızın amacı, 8-18 yaş aralığındaki hastalara ait panoramik radyografilerde dens invaginatuslu dişlerin tespitinde, detection ve segmentasyon teknikleri ile YOLOv5 ve YOLOv8 derin öğrenme modelleri kullanılarak geliştirilen yapay zekâ uygulamasının başarısının ve güvenilirliğinin değerlendirilmesidir.



2. GENEL BİLGİLER

2.1. Dental Anomaliler

Diş gelişimi diğer ismiyle odontogenez, embriyonik dönemin erken evrelerinde gerçekleşen önemli bir süreç olup intrauterin hayatın 6. haftasında ağız boşluğunu döşeyen ektoderm ile mezoderm arasındaki epitelyal-mezenşimal hücrelerin etkileşimiyle başlar. Mine dokusu ektodermden köken alırken, diğer diş yapıları ektodermal epitelin altındaki mezenşimden farklanır. Odontogenezi düzenleyen mekanizma, epitelyal hücreler ve mezenşimal hücreler arasında gerçekleşen karşılıklı ve sıralı etkileşimlerdir. Bu süreçte oral ektoderm kalınlaşır, tomurcuklanıp gelişerek diş kronunun şeklini oluşturur (8).

Odontogenez sürecinde meydana gelen bu sıralı değişiklikler sırasında oluşan duraksamalar ve bozulmalar dişlerin görüntüsünde, boyutlarında ve yapısında normal dişlere kıyasla farklılıkların ortaya çıkmasına neden olur. Dental anomali olarak adlandırılan bu farklılıklar dişlerin normal sayısında, boyutunda, morfolojisinde veya sürme paterninde farklılıklara yol açmaktadır (9).

Dental anomaliler, diş oluşumu sırasındaki deformitelerden kaynaklanan diş yapısındaki değişiklikler olup konjenital, gelişimsel veya edinsel olabilirler (10). Bu anomalilerin gelişmesinde genetik, epigenetik veya çevresel faktörler etkilidir. Konjenital anomaliler kalıtsal olup genetik temele sahiptir. Gelişimsel anomaliler, dişlerin gelişim süreci sırasında meydana gelir ve basit izole kusurlardan spesifik sendromların semptomlarına kadar değişebilir. Edinsel anomaliler ise dişlerin gelişiminden sonra etkili olan faktörlerin etkisiyle ortaya çıkar (9–11). Bununla birlikte bu faktörler prenatal ve postnatal dönemde etkili olarak hem süt hem daimi dişlerde anomalilerin gelişmesine neden olabilir. Dental anomaliler lokalize olarak tek bir dişi ya da diş grubunu etkileyebildiği gibi genel olarak tüm dişleri kapsayacak şekilde de izlenebilir. Ayrıca aynı hastada birden fazla dental anomaliye de rastlanabilmektedir (12).

Anomalinin gelişimi esnasında içinde bulunulan embriyolojik döneme, çeşitli bireysel ve çevresel faktörlerin etkisine bağlı olarak anomalinin tipi ve şiddeti değişebilmektedir. En yaygın görülen gelişimsel dental anomaliler durum, sayı, boyut,

yapı (doku) ve biçim (şekil) anomalileri olarak sınıflandırılabilir (4,9,10).

2.1.1. Durum Anomalileri

Dişlerde konum ve doğrultu değişimi olarak tanımlanan durum anomalileri, edinsel veya kazanılmış olarak ortaya çıkabilirler (9). Transpozisyon, birbirine komşu iki dişin yer değiştirmesi şeklinde tanımlanmakta olup daha çok daimi dişlerde görülmektedir. Sıklıkla alt çenede lateral-kanin, üst çenede ise premolar-kanin ve kanin-lateral arasında görülür. Dişlerin erüpsiyon sırasında sürme yolundan sapması, diş germelerinin yer değiştirmesi ve travma transpozisyonun etiyolojik faktörleri arasındadır (13). Ektopi, dişlerin çeneler üzerinde ancak, diş arkından uzakta yer almasıdır. Heterotopi, dişlerin çene dışında farklı bir organ içerisinde gelişmesine verilen isimdir. Deplasman, dişin çene arkı üzerinde ancak, normal yerinde olmamasıdır. İnversiyon ise, dişin normal erüpsiyon doğrultusundan tamamen ters yönde sürmesidir (9,10).

2.1.2. Sayı Anomalileri

Odontogenezin proliferasyon evresinde oluşan mekanik, kimyasal, travmatik ve enfeksiyon kökenli etkenler nedeniyle normalden sapması, genetik veya kromozomal bozukluklar dişlerde sayı anomalilerine yol açarak dental arktaki diş sayısında artış veya azalmaya neden olabilmektedir (14). Dişlerde görülen bu sayı anomalileri, dental laminanın fiziksel obstrüksiyonuna ya da aşırı aktif olmasına, epitelyal ve mezenşimal dokular arası etkileşimdeki bozukluğa, genetik varyasyonlara, dental epitelyumda fonksiyonel anormalliklere bağlı olarak gelişebilmektedir. Ayrıca bu dental anomaliler bazı sendromlar ve sistemik hastalıklarla birlikte görülebilmektedir (15).

2.1.2.1. Hiperdonti

Diş sayısında artış ile karakterize gelişimsel bir anomalidir. Fazla sayıdaki dişler, morfoloji ve lokasyona bakılmaksızın 'süpernümerer diş' olarak tanımlanır. Bu durum tek veya birden fazla, unilateral veya bilateral olup süt veya daimi dentisyonda görülebilir. En sık rastlanan süpernümerer dişler, maksiller orta hatta santral dişler arasında bulunmaktadır ve bu dişlere 'mesiodens' adı verilmektedir (16).

2.1.2.2. Hipodonti

Süt ve daimi dişlenme döneminde diş germelerinin doğuştan yokluğu 'konjenital diş eksikliği' olarak tanımlanmaktadır. Hipodonti, en sık karşılaşılan gelişimsel dental anomali olup üçüncü büyük azı dişi hariç bir veya daha fazla süt veya daimi dişin gelişimsel olarak eksikliğini tanımlamak için kullanılır (17). Altı veya daha fazla dişin eksikliğine 'oligodonti', tüm dişlerin eksikliğine ise 'anodonti' adı verilmektedir.

Hipodonti, kromozom anomalileri, genetik geçiş ve bazı sendromlar gibi etiyolojik faktörlerle ilişkilendirilmektedir. Ayrıca diş sayısı ile ilgili anomalilerle ilişkili çevresel faktörler arasında annenin hamilelik sırasında geçirdiği enfeksiyonlar, ilaç kullanımı, radyoterapi ve kemoterapi gibi faktörler bulunmaktadır. Konjenital olarak en sık eksiklik, üçüncü molar dişler, üst lateral dişler ve alt ikinci premolar dişlerde görülmektedir (18).

2.1.3. Boyut Anomalileri

Diş gelişiminin morfodiferansiyasyon aşamasındaki bozukluklardan biri olan boyut anomalileri gelişimsel, konjenital veya edinsel kaynaklı görülebilmektedir. Boyut anomalileri cinsiyet ve ırka göre değişiklik gösterebilmekte, izole veya sistemik durum ve sendromlarla ilişkili olarak ortaya çıkabilmektedir. Boyut anomalileri, makrodonti ve mikrodonti olarak ikiye ayrılmaktadır (19).

2.1.3.1. Makrodonti

Makrodonti, dişlerin normalden daha büyük olması durumu olarak tanımlanan anomalidir ve dişin mesio-distal ve fasiyo-lingual boyutlarında artış ile karakterizedir. Etiyolojisinde çevresel ve genetik faktörlerin etkili olduğu düşünülmektedir (20).

2.1.3.2. Mikrodonti

Mikrodonti, dişlerin normal boyutlarından daha küçük olma durumu olarak tanımlanmakta ve diş gelişiminin morfodiferansiyasyon aşamasında meydana gelen bozukluklardan kaynaklanmaktadır. Bununla birlikte mikrodontinin çevresel ve genetik faktörleri içeren karmaşık bir etiyolojiye sahip olduğu düşünülmektedir. Literatürde çoğu mikrodonti vakasının maksiller lateral dişlerde olduğu görülmektedir (21).

2.1.4. Yapı (Doku) Anomalileri

Dişlerin histolojik yapısında değişikliklerin görüldüğü durumlara yapı (doku) anomalileri denir. Dişlerin kalsifiye dokularındaki bu bozukluklar, mine ve dentinde değişikliklere yol açarak dişlerin hacim, şekil ve rengini etkileyebilir. Bu yapısal bozuklukların nedenleri arasında genetik, endojen bozukluklar, konjenital metabolizma bozuklukları, enfeksiyonlar ve beslenme sorunları yer almaktadır (22).

2.1.4.1. Amelogenesis İmperfekta

Amelogenesis imperfekta, her iki diş dizisinde de görülen ve tüm dişleri etkileyen genetik kökenli bir mine formasyon bozukluğudur. Bu hastalık klinik görünüm ve kalıtım özelliklerine göre sınıflandırılmaktadır. En yaygın kabul gören sınıflamaya göre 4 tip ve alt grupları vardır (23).

a) Tip I Amelogenesis İmperfekta (Hipoplastik tip): İnce, fakat mineralize translüsent mine ile karakterizedir. Minenin eksikliği veya azlığı, sekresyon fazındaki problemlere bağlanır. Bu durumda ameloblastlar mine proteinlerinin yerine proteinazlar salgılar ve mine normalden ince olur. Dişler sarımsı kahverengi, pürüzlü ve girintili yüzeylere sahiptir. Radyografide mine, dentinden daha radyoopaktır.

b) Tip II Amelogenesis İmperfekta (Hipomatür): Mine normal kalınlıktadır ancak, proteinlerin yetersiz yıkımı nedeniyle mine benekli ve koyu kahverengi-sarı renktedir. Mine yumuşaktır ve ciddi aşınma ve kırılmalar görülebilir. Radyografik olarak dentinle benzer radyodansite gösterir.

c) Tip III Amelogenesis İmperfekta (Hipokalsifiye): Mine kalsifikasyonunda problem vardır. Mine normal kalınlıktadır ancak, çok yumuşaktır ve dişler sürdükten sonra hızla yıkıma uğrar. Dişler, opak veya tebeşirimsi bir görüntüye sahiptir ve termal uyarılara karşı hassastır. Radyografik olarak mine dentine göre daha az radyoopaktır.

d) Tip IV Amelogenesis İmperfekta (Taurodontizmle birlikte görülen hipomatür-hipoplastik): Hipoplastik ve hipomatür tiplerin karışımıdır. Radyografide pulpa odasının genişlediği ve furkasyon noktasının kökün apikaline yaklaştığı taurodontizm bulguları görülür (23–25).

2.1.4.2. Dentinogenezis İmperfekta

Dentinogenezis imperfekta hem süt hem de sürekli dişlerin etkilendiği, anormal dentin yapısıyla karakterize otozomal dominant geçişli bir anomalidir. Dentinogenezis İmperfekta'nın sınıflandırılmasında en çok kabul gören sistem Shields ve arkadaşlarının sistemidir (26,27). Dentinogenezis imperfekta klinik ve radyolojik bulgulara göre üç tipe ayrılmıştır:

- a) Tip I Dentinogenezis İmperfekta: Osteogenezis imperfekta ile birlikte görülen sendromik formdur. Hem süt hem de daimi dişler etkilenebilir, ancak en çok süt dişleri etkilenir. Radyografik olarak çan veya soğan şeklinde kron yapısı, köklerde daralma ve tıkanmalar görülür. Dişlerde gri-mavi, sarı-kahverengi renklenmeler ve aşınma mevcuttur (26,28).
- b) Tip II Dentinogenezis İmperfekta: Sendromik olmayan kalıtsal opalasant dentin olarak da bilinir. Hem süt hem de daimi dişler eşit oranda etkilenir. Dişler şeffaf, mavimtrak-kahverengimsi renktedir. Radyografide pulpa odasında daralmalar görülür. Diş çürüğü olmasa bile diş eti hastalıkları gelişebilir (26,29).
- c) Tip III Dentinogenezis İmperfekta: Daha nadir görülür ve her iki diş dizisini de etkiler. Daimi dişlerde çan şekilli kronlar ve mine çukurukları belirgindir. Dişler, deniz kabuğu (shell teeth) görünümündedir (28,30).

2.1.4.3. Dentin Displazisi

Dentin displazisi, her 100.000 kişide bir görülen süt dişleri, daimi dişleri veya her iki dentisyonu da etkileyebilen otozomal dominant geçişli nadir bir anomalidir (26). Ballschmiede tarafından 1920'de "köksüz dişler" olarak rapor edilen bu durum, 1939'da Rushton tarafından dentin displazisi olarak adlandırılmıştır. 1972 yılında Witkop, radyolojik bulgulara dayanarak dentin displazisini 'Tip I Radiküler Dentin Displazisi' ve 'Tip II Koronal Dentin Displazisi' olarak sınıflandırmıştır (31).

-Dentin Displazisi Tip I (Radiküler Dentin Displazisi): Dişlerin rengi normalden açık maviye veya açık kahverengiye kadar değişebilir. Her iki diş dizisi de etkilenir ve radyografide kron morfolojisi normal iken kökler kısa ve künttür (32).

-Dentin Displazisi Tip II (Koronal Dentin Displazisi): Daimi dişler normal renkte olup, pulpa odası deve dikeni veya alev şeklindedir ve pulpa taşı izlenir. Süt dişlerinde ise klinik ve radyolojik olarak dentinogenezis imperfekta tip II'den ayırt etmek zordur (32).

2.1.4.4. Rejyonel Odontodisplazi

Rejyonel odontodisplazi (odontogenezis imperfekta) mine, dentin ve pulpanın etkilendiği lokalize, nadir görülen gelişimsel bir anomalidir. Etiyolojisi tam olarak belli olmamakla birlikte travma, enfeksiyon, beslenme, metabolik anomaliler ve genetik faktörler sorumlu tutulmaktadır. Genellikle çenenin bir kadranındaki bir veya daha fazla komşu diş etkilenir. En sık maksiller anterior bölgede görülmekle birlikte hem süt hem daimi dişlenme döneminde görülebilir. Etkilenen dişlerde hipoplazi ve sürme gecikmesi izlenir. Radyografik olarak etkilenmiş dişler, etkilenmemiş dişlere göre daha az opak görünür ve mine-dentin sınırı ayırt edilemez (33,34).

2.1.5. Biçim (Şekil) Anomalileri

Biçim (şekil) anomalileri, odontogenezin morfodiferansiyasyon aşamasında başlayıp ve belirli diş veya diş gruplarını etkileyen, dişlerin normal biçimlerinden sapması durumudur. Biçim bozukluklarının gelişiminde genetik ve çevresel faktörler etkili olabilir. Ayrıca, konjenital anomalilerle birlikte görülen bazı belirgin morfolojik bozukluklar da mevcuttur (35).

2.1.5.1. Füzyon

Füzyon, gelişmekte olan iki veya üç diş germinin birleşimi ile tek bir dişin oluşması olarak tanımlanmaktadır. Birleşme, kalsifikasyon öncesinde gerçekleşirse oluşan diş genellikle normal boyutlarındadır (36). Ancak, diş gelişiminin daha geç evrelerindeki birleşme ile normalden daha büyük veya kronu ikiye ayrılmış bir diş meydana gelebilir. Süt dentisyonda daimi dentisyona göre daha sık görülür ve özellikle kesici ve kanin dişler etkilenir. Diş tomurcukları arasındaki yakın temasa sebep olan sıkışma veya gelişim sırasında çeneleri etkileyen fiziksel kuvvetlerin bu anomaliye neden olabileceği düşünülmektedir (9,37,38).

2.1.5.2. Geminasyon

Bölünmeye çalışan tek bir diş tomurcuğunun gelişimi sırasında, etkenin şiddeti ve süresine bağlı olarak tam olarak ayrılamaması durumu 'geminasyon' olarak bilinmektedir (37). Bu dişler mesio-distal çapı genişlemiş bir kron, tek kanal ve tek kök içerir. Dental arktaki diş sayısında bir azalma olmaz. Füzyonlu dişlerde radyografik olarak iki ayrı pulpa kanalı izlenirken, geminasyonlu diş tek bir pulpa kanalı ve köke sahiptir (9,37,38).

2.1.5.3. Konkresens

Gelişimini tamamlamış komşu diş köklerinin travma ve çapraşıklık gibi nedenlerden ötürü sement seviyesinde birleşmesi olayıdır. Çevresel basınç etkisiyle kökler arasındaki interdental kemik rezorbe olur ve sement apozisyonu ile kökler kaynaşır. Bu olay, dişlerin erüpsiyonundan önce veya sonra gerçekleşebilir. En sık maksiller ikinci ve üçüncü molarlar arasında gözlenir ve bu durumun, maksiller molar dişlerin kronlarının distale eğimli oluşundan kaynaklı olabileceği düşünülmektedir (38).

2.1.5.4. Dilaserasyon

Dilaserasyon, dişin kron veya kök ekseninde meydana gelen anormal açılanma veya keskin eğimdir. Daimi dişlerde dilaserasyonun en yaygın olarak kabul edilen nedeni, gelişmekte olan diş germine gelen travmadır. Dişe gelen travmanın şiddeti ile dilaserasyonun şiddeti doğru orantılıdır. Ayrıca etiolojisinde gelişimsel sendromlar, skar oluşumu, diş germinin gelişimsel anomalisi, kök enfeksiyonu, diş germinin ektopik gelişimi, kist, tümör veya odontojenik hamartom varlığı, kalıtsal ve genetik faktörler gibi pek çok faktörün etkili olabileceği öne sürülmüştür (39).

2.1.5.5. Taurodontizm

Taurodontizm, radyografik olarak dikey olarak uzamış bir pulpa odası, apikal olarak yer değiştirmiş bir pulpa tabanı ve normalden daha kısa bir kök/kanal yapısı ile kendini gösterir (40). Taurodontizm tek başına görülebildiği gibi Down sendromu, Klinefelter sendromu, ektodermal bozukluklar, ora-fasio-digital sendrom, Amelogenesis İmperfekta ile birlikte de görülebilmektedir. Patogenezi tam olarak anlaşılamamış olsa da Hertwing epitel kök kınının horizontal seviyede invajinasyonundaki bozulması

nedeni ile ortaya çıktığı düşünülmektedir (41).

2.1.5.6. Dens Evaginatus

Dens evaginatus, dişlerin oklüzal yüzeylerinde koni şeklinde bir aksesuar tüberkül ile karakterizedir. Bu aksesuar tüberkül mine, dentin ve sıklıkla pulpa dokusu içerir. Bu nedenle dens evaginatusun erken teşhis ve tedavisi oldukça önemlidir. Çiğneme sırasında oluşan travma, tüberkülün aşınmasına veya kırılmasına yol açarak pulpa nekrozuna ve periapikal enfeksiyona neden olabilir. Bu anomali, süt ve daimi dentisyonda özellikle premolar dişlerde sık görülmekle beraber kesici, kanin ve molar dişlerde de görülebilmektedir (42).

Dens evaginatus çürük, periapikal lezyonlar, dilin ve diğer yumuşak dokuların irritasyonu, tüberkülde kırılmalar ve periodontal problemler gibi çeşitli klinik problemlere yol açabilir. Tedavi, evaginasyonun şekline ve boyutuna bağlı olarak konservatif veya radikal olabilir. Tedavi yöntemleri arasında aşamalı olarak tüberküllerin möllenmesi, tüberkül yapısını güçlendirmek amacıyla rezin uygulamaları, tüberkülleri uzaklaştırdıktan sonra koruyucu restorasyonlar ve kavite preparasyonları bulunur (42,43).

2.2. Dens Invaginatus

Dens invaginatus, diş dokularının kalsifikasyonundan önce mine organının dental papilla içine doğru invajinasyonu ile ortaya çıkan gelişimsel dental anomalidir (1,44). Ploquet tarafından ilk kez 1794 yılında balina dişinde keşfedildikten sonra tanımlanmıştır (44). İnsan dişlerinde ise ilk kez 1856 yılında Sokrates isimli diş hekimi tarafından rapor edilmiştir (45). Bu durumu tanımlamak için ‘dens in dente’, ‘dentoid in dente’, ‘invaginasyonlu odontom’, ‘dilate gestant odontom’, ‘dilate kompozit odontom’ ve ‘diş inklüzyonu’nu içeren çok sayıda farklı terim kullanılmıştır (1,44). Farklı isimlendirmeler bu durumun oluşumu, etiyojisi ve sınıflandırılması konusunda fikir birliği olmadığını yansıtmaktadır (46).

Dens invaginatus, çoğunlukla daimi dişleri etkileyen gelişimsel bir anomalidir ancak, süt dişlerinde görüldüğünü bildiren vaka raporları da mevcuttur (47). Dens invaginatus en sık daimi maksiller lateral dişlerde, ardından maksiller santral dişlerde,

kanin dişlerde, premolar dişlerde ve daha az sıklıkla da molar dişlerde görülür. Ayrıca, nadiren de olsa süpernumerer dişlerde görülebilmektedir (48). Sıklıkla maksiller dişlerde görülmesine rağmen mandibulada da dens invaginatus vakaları rapor edilmiştir (49).

2.2.1. Dens İnvaginatusun Etiyolojisi

Dens invaginatusun etiyojisini açıklamak için çeşitli teoriler öne sürülmüştür ancak, bu malformasyonun altında yatan neden konusunda bir fikir birliği yoktur. Kronfeld (1934), sorunun iç mine epitelinin büyümesindeki fokal bir başarısızlıktan kaynaklandığını öne sürmüştür (50). Rushton (1958), bu anomalinin nedeninin diş gelişimi sırasında mine organı hücrelerinin dental papillaya doğru uyarılması ardından çoğalması ve büyümesi nedeniyle embriyolojik olduğunu ileri sürmektedir (51). Diğer bir görüş ise gelişim sırasında komşu diş germlerinin neden olduğu dış kuvvetlerden kaynaklanan etkidir. Travma ve enfeksiyon gibi faktörler de bu anomalinin nedenleri olarak öne sürülmüştür (52,53).

Diş gelişimi sırasında dental papilla ile iç mine epiteli arasında meydana gelen ektomezental sinyal sistemleri morfogenezi etkiler (54). Bu sinyallerin büyümenin düzenlenmesi gibi spesifik rolleri vardır (55). Bazı moleküllerin eksikliği anormal diş şeklinin yanı sıra gelişen diş germinde de bozukluklara neden olabilir (56). Bu sebeple genetik faktörlerin dens invaginatusun nedeni olabileceği önerisi ortaya atılmıştır (57–60). İnvajinasyonların sınırlı varyasyona sahip olması ve aynı bireyde veya kardeşlerde birden fazla dişte meydana gelebilmesi de genetik etkiyi düşündürmektedir (59,61).


Dens invaginatus ayrıca Williams, Nance-Horan ve Ekman-Westborg-Julin sendromu gibi bazı genetik bozukluklarla da ilişkili bulunmuştur (62). Pokala ve Acs (1994), kromozom 7q32'den yoksun bir bireyde hipodonti gibi diğer diş anomalilerine ek olarak dens invaginatus bulunduğunu bildirmiştir (63).

2.2.3. Dens İnvaginatusun Sınıflandırılması

Dens invaginatusu tanımlamak için farklı sınıflandırmalar önerilmiştir. Dens invaginatus anomalisini sınıflandırmaya yönelik ilk girişim, klinik ve radyografik kriterlere dayanarak üç tip invajinasyonun varlığını öne süren Hallet tarafından 1953

yılında yapılmıştır (64). Bununla birlikte farklı standart ve kriterler içeren farklı sınıflandırmalar da tanımlanmıştır (65,66). Schulze & Brand, 1972 yılında insizal kenardan veya kron tepesinden başlayan invajinasyonları içeren ve ayrıca dismorfik kök konfigürasyonunu tanımlayan daha ayrıntılı bir sınıflandırma önermiştir (67).

En sık kullanılan sınıflandırma, dens invaginatüsü penetrasyon derinliğine ve periapikal doku veya periodontal ligament ile iletişimine göre üç kategoriye ayıran Oehlers tarafından önerilmiştir (61) (Şekil 2.1). Oehlers tarafından tanımlanan bu sistem, kolay isimlendirilmesi ve uygulamadaki kolaylık nedeniyle en yaygın kullanılan sınıflama olarak görünmektedir (1).



Şekil 2.1: Oehler's sınıflaması (1957) (68)

Oehlers Sınıflaması;

Tip I: İnvajinasyon dişin kronu ile sınırlıdır ve mine-sement birleşimi seviyesinin ötesine geçmez.

Tip II: İnvajinasyon mine-sement birleşiminin ötesine apikal yönde kör bir kese şeklinde uzanır ancak, periodontal ligamentle bağlantısı olmaksızın kök içinde sınırlı kalır.

Tip IIIA: İnvajinasyon dişin kökü boyunca uzanarak psödo-foramen yoluyla periodontal ligament boşluğu ile lateral olarak iletişim kurar. Genellikle pulpal bir tutulum gözlenmez ancak, önemli bir anatomik malformasyona neden olur.

Tip IIIB: İnvajinasyon diş kökü boyunca uzanır ve apikal foramende periodontal ligament ile iletişim kurar. Pulpa tutulumu genellikle doğrudan görülmez (61).

İnvajinasyonun orjinine göre dens invaginatus koronal ve radiküler olarak da sınıflandırılabilir (69).

a) Koronal dens invaginatus: Mineralizasyondan önce mine organının dental papillaya invajinasyonu sonucu oluşur (1,44). Oehlers sınıflamasında koronal dens invaginatus radyografik görünümüne göre üç tipe ayrılmıştır (61).

b) Radiküler dens invaginatus: Hertwig epitel kök kımının kron gelişimi tamamlandıktan sonra kök içine doğru katlanmasıyla oluşur (69). Radiküler dens invaginatusun iki alt tipi bulunmaktadır:

-Birinci alt tipe, invajinasyon sementle kaplıdır ve bir kök oluşuyla ilişkilidir (70). Bu tip daha çok kök morfolojisinin bir varyasyonuna benzer (71). 1968 yılında Lee ve arkadaşları bu anomaliyi palatogingival oluk olarak adlandırmışlardır (72). Daha sonra radiküler oluk veya gelişimsel radiküler anomali gibi başka terimler de önerilmiştir (73,74). Günümüzde bu defektin tanımlanmasında klinikte radiküler oluk yaygın olarak kullanılmaktadır (48).

-Radiküler dens invaginatusun ikinci alt tipi, kök içinde mine kaplı bir invajinasyondan oluşur. Etiyolojisi, epitel hücrelerinin Hertwig kök kımından ameloblastlara farklılaşmasıyla ilişkili olabilir (75). Radyografik olarak tip III koronal dens invaginatus ile karıştırılabilir. Tip III dens invaginatus, invajinasyon hem kron hem de kökte görülürken radiküler dens invaginatus sadece kökte tutulum mevcuttur (48).

2.2.4. Dens İnvaginatusun Prevalansı

Dens invaginatusun farklı çalışmalarda bildirilen prevalansı %0,3 ila %10 arasında değişmektedir (76,77). Literatür gözden geçirildiğinde farklı popülasyonlarda dens invaginatus prevalansında geniş bir farklılık olduğu görülmektedir. Rapor edilen prevalanstaki değişkenlikler coğrafî farklılıklar, kullanılan farklı tanı kriterleri ve inceleme yöntemleri ile açıklanabilir (78,79).

Tablo 2.1: Dens invaginatus prevalansı üzerine yapılan çalışmalar

YAZAR	YIL	ÜLKE	RADYOGRAFİK TEKNİK	ÖRNEK SAYISI	PREVALANS
Backman ve Wahlin (83)	2001	İsveç	İntraoral ve ekstraoral radyografiler	739 hasta	%6,8
Hamasha ve Al-Omari (49)	2004	Ürdün	Periapikal radyografi	1660 hasta	%2,95
Ezoddini ve ark. (84)	2007	İran	Panoramik radyografi	480 hasta	%0,8
Kırzıoğlu ve Ceylan (82)	2009	Türkiye	Periapikal ve panoramik radyografi	2477 hasta	%12
Çakıcı ve ark. (80)	2010	Türkiye	Periapikal ve panoramik radyografi	1012 hasta	%1,3
Çolak ve ark. (85)	2012	Türkiye	Panoramik radyografi	6912 hasta	%2,95
Gündüz ve ark. (81)	2013	Türkiye	Periapikal ve panoramik radyografi	4556 hasta	%2,5
Patil ve Doni (86)	2013	Hindistan	Periapikal radyografi	3320 hasta	%2,4
Ceyhanlı ve ark. (87)	2015	Türkiye	KIBT (Konik Işınlı Bilgisayarlı Tomografi)	2067 hasta	%5,9
Çapar ve ark. (88)	2015	Türkiye	KIBT ve panoramik radyografi	300 hasta	%10,7
Rózyło ve ark. (89)	2017	Polonya	KIBT	33 hasta	%53,7
Mabrouk ve ark. (90)	2021	Tunus	KIBT	200 hasta	%12,5
Alkadi ve ark. (91)	2021	Suudi Arabistan	KIBT	505 hasta	%7,3
Chen ve ark. (92)	2021	Çin	KIBT	1004 hasta	%8,47
Hegde ve ark. (93)	2022	Hindistan	KIBT	7048 hasta	%1,1
Yalçın ve ark. (94)	2022	Türkiye	KIBT	958 hasta	%5,11
Varun ve ark. (95)	2022	Hindistan	KIBT	163 hasta	%13,5

Türk popülasyonunda dens invaginatus prevalansı %1,3-12 arasında değişmektedir (80–82) Gündüz ve arkadaşlarının yaptıkları çalışmada değerlendirilen hastaların %2,54'ünde dens invaginatus tespit edilmiştir (81). Çakıcı ve arkadaşları çalışmalarında %1,3 prevalans bildirirken, Kırzioğlu ve Ceyhan'ın yapmış olduğu çalışmada dens invaginatus prevalansı %12 olarak bulunmuştur (80,82). Erişilebilir literatürdeki 2000 yılı sonrasında yapılan dens invaginatus prevalansı ile ilgili çalışmalar Tablo 2.1'de belirtilmiştir.

Oehlers'in sınıflandırması kullanılarak yapılan bir çalışmada, her bir dens invaginatus tipinin prevalansı, tip I (%79), tip II (%15) ve tip III (%5) olarak bildirilmiştir (68). Çakıcı ve arkadaşlarının yaptığı çalışmada, tip I %81,25 prevalans ile en yaygın dens invaginatus tipi olmuştur (80). Ayrıca dens invaginatus sıklıkla bilateral görülmekte ve taurodontizm, mikrodonti, geminasyon, hipodonti ve dentinogenezis imperfekta gibi diğer anomalilerle ilişkilendirilmektedir (76,96,97). Literatürde genel olarak dens invaginatus prevalansı ile cinsiyet arasında ise bir ilişki bildirilmemiştir (91,93).

2.2.5. Dens İnvaginatusun Klinik Değerlendirmesi

Dens invaginatus, yaygın görülmesine rağmen anomalinin belirgin klinik bulgularının olmaması sebebiyle gözden kolayca kaçabilmektedir. İnvajinasyonun varlığı çürük, pulpal patoloji ve periodontal enflamasyon riskini arttırabilmektedir. Ayrıca, anomalinin doğası gereği gerekli endodontik tedavi genellikle komplike olabilmektedir. Bu nedenle, dens invaginatusun etkilenmiş bir dişin erken teşhisi oldukça önemlidir (98,99).

Dişin palatal veya oklüzal yüzeyindeki derin foramen caecum, invajinasyonun girişidir (Şekil 2.2). İnvajinasyon girişinin çok belirgin olmadığı durumlarda klinik olarak teşhis zor olabilmektedir. Bu gibi durumlarda teşhise yardımcı olmak için metilen mavisi boyası kullanılabilir (100).



Şekil 2.2: Dens invaginatusun klinik görünümü (101)

Spesifik bir kron morfolojisi dens invaginatus varlığına işaret edebilir. Literatüre dayanarak dens invaginatusun klinik belirtileri aşağıdaki gibi özetlenebilir:

1. İnvajinasyonun girişi olan palatinal pit veya oluk
2. Kesici kenarın bulunmadığı veya servikal-lingual kenarların yüksekliğinin arttığı koni biçimli dişler
3. Genellikle artan labial-lingual ve/veya mezio-distal çap veya genişlemiş singulumla birlikte genişlemiş kronlar
4. Mikrodontik dişler
5. Belirgin palatal singulum veya Talon tüberkülü varlığı
6. Labial oluk ile birlikte insizal çentik varlığı (61,97).

Dens invaginatus malformasyonlarına ilişkin literatür, invajinasyonlu dişlerin diğer anomaliler, malformasyonlar ve hatta dental veya medikal sendromlarla birlikte görülebildiğini gösteren çok sayıda vaka raporu içermektedir (44). Bu nedenle anormal diş morfolojisi gözlemlendiğinde olası invajinasyon varlığını göz önünde bulundurmak faydalı olabilir.

İnvajinasyon, mikroorganizmalar ve iritanlar için pulpaya potansiyel bir geçiş oluşturarak inflamasyona ve nekroza neden olabilir (49). Apse oluşumu, internal rezorpsiyon, dişte yer değiştirme ve komşu dişlerin retansiyonu dens invaginatus ile ilişkili diğer klinik problemlerdir (102). Ek olarak, irreversible pulpitis veya apikal

periodontitis semptomları olan ancak, çürük veya travma öyküsü bulunmayan tüm vakalarda, özellikle de lateral dişlerin etkilendiği durumlarda dens invaginatus olasılığı göz önünde bulundurulmalıdır (103).

Etkilenen diş aynı zamanda pulpal patolojilerle ilişkilendirilen belirti ve semptomlar gösterebilir ya da bunlara dair bir geçmişe sahip olabilir (61,79). Bu nedenle, pulpal semptomlar için başka belirgin bir nedeni olmayan dişlerde, özellikle anomali ile ilişkili diğer özellikler mevcutsa, bir invajinasyonun varlığı düşünülmelidir (104). Benzer şekilde, bilateral görülebildiği için bir tarafta dens invaginatus tespit edildiğinde kontra-lateral dişin klinik ve radyografik muayenesinin yapılması önemlidir (60).

2.2.6. Dens İnvaginatusun Radyografik Değerlendirmesi

Oehler's tip I dens invaginatus'ta invajinasyon minimal olup mine ile kaplı ve kronla sınırlı radyolüsent hat şeklinde izlenmektedir (48).

Oehler's tip II dens invaginatus, radyografilerde mineye benzer bir yoğunlukta, derinlik ve şekil açısından değişen, merkezi radyolüsent olan, pulpaya ilerleyen radyopak görüntü şeklinde izlenmektedir (97). İnvajinasyon mine-sement birleşiminin ötesinde kör bir kese şeklinde uzanır ancak, periodontal ligamentle bağlantısı olmadan kök içinde sınırlı kalır. Tip I ve tip II dens invaginatus ayrımı invajinasyonun mine-sement sınırını geçip geçmemesi ile yapılır (48).

İnvajinasyon koronal ve radiküler kısmı kapladığında, pulpa boşluğunun ana hatları değişerek pulpa boynuzlarının 'küntleşmesine' neden olabilir. Defektin boyutu ve şekli halka benzeri, armut biçimli veya hafif radyolüsent bir yapıdan 'diş içinde diş'i andıran şiddetli bir forma kadar değişebilir. İnvajinasyonun ana hatları genellikle opak bir mine tabakası ile iyi tanımlanır (1,44).

Oehler's tip III dens invaginatus'ta mevcut invajinasyon radyopak sınırla çevrelenmiş radyolüsent alan şeklinde izlenir. İnvajinasyon ile ana kanalın göreceli konumu farklı olabilir ve invajinasyon ile ana kanal arasında iletişim olmayabilir. İnvajinasyon, mine-sement birleşiminin ötesine uzanır ve psödo-foramen yoluyla lateral olarak veya apikal foramende periodontal ligament ile bağlantı kurar.

Tip IIIa, kökün lateral yüzeyinden çıkan dişte derin bir fissür şeklinde görülür. İnvajinasyona komşu kök kanalı dalgalı ve anormal olabilir. Buna karşılık, tip IIIb'yi tanımlamak ve tam olarak yerini belirlemek daha zordur çünkü kök kanalının içinden apikal olarak çıkan kök kanal sisteminin üzerine süperpoze olmuştur. Bu apikal oluşum immatür bir apeksle ortaya çıkabilir ve çoğu vakada radyografik değerlendirme, etkilenen dişle birlikte periapikal radyolüsent bir lezyonu gösterir (100).



Şekil 2.3: Dens invaginatusun iki boyutlu radyografik görüntüsü (105)

Dens invaginatus tanısı için iki boyutlu görüntüleme yöntemlerinden periapikal radyografiler veya panoramik radyografiler kullanılabilir (Şekil 2.3). Dens invaginatus lezyonlarını tanımlamak periapikal radyografi tercih edildiğinde lezyonun tek bir görüntüde maskelenmediğinden emin olmak ve invajinasyonun yayılımını daha iyi anlayabilmek için yatay açıda 15°'lik bir değişiklik yapılarak ikinci bir radyografinin elde edilmesi tavsiye edilir (97,106).

Bununla birlikte, geleneksel radyografiler yalnızca iki boyutlu görünümü gösterdikleri için karmaşık anatomiye sahip dens invaginatus vakalarında yetersiz olabilmektedir (107). Konik ışınlı bilgisayarlı tomografi (KIBT), kök kanal anatomisinin ve dens invaginatus anomalisinde görülen karmaşık anatomik varyasyonların değerlendirilmesinde geleneksel radyografinin sınırlamalarının üstesinden gelerek daha detaylı bir radyografik değerlendirmeye olanak sağlar (108).

KIBT görüntülerinin kullanımı dens invaginatus tipini değerlendirme, kök kanal sistemi içindeki boyutunu daha detaylı gözlemlenme, planlanan endodontik tedavinin

değerlendirilmesi ve apikal cerrahi planlanıyorsa komşu anatomik yapıların yakınlığının değerlendirilmesine yardımcı olur (68,90).

Dens invaginatus, diş sürmeden önce de radyografik olarak teşhis edilebilmektedir. Bu nedenle, anomaliden şüpheleniliyorsa ayrıntılı bir radyografik inceleme önemlidir. Bununla birlikte, dens invaginatus vakalarında doğru tanı çoğunlukla filmin kalitesine, klinisyenin bilgi birikimi ve deneyimine bağlıdır (97).

2.2.7. Dens İnvaginatuslu Dişlerin Histolojisi

Dens invaginatus malformasyonuna sahip dişlerin mikroskobik, ultrastrüktürel ve mikroradyografik incelemelerine ilişkin çeşitli raporlarda farklı bulgular mevcuttur (44). Bu dişlerde invajinasyonun altındaki dentin, düzensizlikler olmaksızın sağlam olabilir ancak, aynı zamanda vital bağ dokuları veya pulpaya bağlantısı olan ince kanallar içerebilir (109,110). Bazı yazarlar bu dişlerde hipomineralize veya düzensiz yapılu dentin bildirmiştir (110,111).

İnvajinasyonu çevreleyen minenin yapısı ve kalınlığı büyük farklılıklar gösterebilmektedir. Beynon, invajinasyonun tabanında hipomineralize mine rapor ederken; Morfis, kimyasal bir analizde dış mineye kıyasla sekiz kata kadar daha fazla fosfat ve kalsiyum tespit etmiştir (111,112). Bloch-Zupan ve arkadaşları ise dış ve iç mine arasında yapı ve bileşim açısından farklılıklar bulmuşlardır. İç mine atipik ve daha karmaşık çubuk şekilleri sergilemiş ve yüzeyi tipik bal peteği deseni göstermiş ancak, dişin dış yüzeyinde gözlenen perikimata görülmemiştir (44).

2.2.8. Dens İnvaginatuslu Dişlerde Tedavi Planlaması

Dens invaginatusun karmaşık anatomisi bu tür dişlerin tedavisini zor ve öngörülemez hale getirmektedir. Dolayısıyla konservatif tedavilerden kök kanal tedavisine, cerrahi tedavi veya çekime kadar değişen çeşitli tedavi yöntemleri tanımlanmıştır (69). Fonksiyon ve estetik, invajinasyonun tipi, kök kanal sisteminin konfigürasyonu, dişin kök gelişim aşaması, protetik ve ortodontik tedavi ihtiyacı, zaman ve ekonomik faktörler tedavi seçiminde etkili olan faktörlerdir (97).

2.2.8.1. Oehlers Tip I Dens İnvaginatusun Tedavisi

İnvajinasyon bölgesinin dışın kronu ile sınırlı olduğu ve pulpanın sağlıklı olduğu durumlarda, izolasyon sağlanır sağlanmaz profilaktik tedavi başlatılmalıdır. Özellikle dens invaginatus bulunan kök gelişimi tamamlanmamış immatür dişlerde endodontik tedavi zor olabileceğinden koruyucu-önleyici tedaviler oldukça önemlidir (113).

İnvajinasyon girişini kapatmak için fissür örtücü veya akıcı kompozit rezin materyali kullanılabilir. Klinik olarak invajinasyon girişinin tespit edilemediği ancak, radyografik olarak invajinasyonun izlenebildiği durumlarda defekt bakteriyel kontaminasyon için bir yol olabileceğinden aynı prosedür takip edilmelidir. Tedavi sonrası bu dişler olası pulpa inflamasyonu ve restorasyonun kontrolü için düzenli olarak takip edilmelidir (100).

Tip 1 dens invaginatuslu dişte pulpa enfekte ise endodontik tedavinin yapılması gerekir. Tedavi, pulpal enfeksiyonun yaygınlığına ve apikal foramenin durumuna bağlı olarak değişir. Özellikle immatür dişlerde, inflamasyonun sınırlı olduğu düşünülen durumlarda pulpotomi düşünülebilir. Pulpanın yaygın şekilde enfekte olması veya periapikal lezyonun mevcut olması durumunda kök kanal tedavisine ihtiyaç vardır. Dikkat edilmesi gereken en önemli nokta, invajinasyonun yeterli debridmanının ve temizliğinin sağlanmasıdır. İnvajinasyonun tamamen temizlendiğinden emin olmak için kavite büyütme altında dikkatli şekilde incelenmelidir. Yaygın pulpitisli veya periapikal lezyonlu etkilenen immatür dişlerin tedavisinde apeksifikasyon veya pulpa revaskülarizasyonu daha uygundur. Genel olarak apikal cerrahiye yalnızca endodontik tedavi semptomlarının kontrol altına almada başarısız olduğu veya periodontal tutulumun olduğu durumlarda ihtiyaç duyulur (114).

2.2.8.2. Oehlers Tip II Dens İnvaginatusun Tedavisi

Tip II dens invaginatuslu dişlerdeki invajinasyon, tip I'e göre daha şiddetlidir ve pulpa ile ilişkili olabilir. Etkilenen dişlerde çürük yoksa, tip I'de olduğu gibi invajinasyonların koruyucu olarak örtülmesi tercih edilebilir. Ancak, bazen çürükler bu lezyonların derinlerinde gelişerek mine yüzeyinin sağlam görünmesine ve altta yatan çürüklerin klinik olarak tespit edilememesine neden olabilir. Bu nedenle invajinasyonun

dikkatli bir şekilde incelenmesi, temizlenerek örtülmesi için koronal giriş hazırlamak daha uygun olabilir (100).

Etkilenen dişte çürük varsa ancak, pulpa vitalse tedavi invajinasyonla sınırlı olmalıdır. Pulpa enfekteyse veya dişte periapikal lezyon mevcutsa kök kanal tedavisi endikedir. İnvajinasyon köke uzandığı için tedavi, tip I dens invaginatus ile karşılaştırıldığında daha karmaşıktır. Tedavi hem invajinasyon kanalının hem de ana kanalın ayrı ayrı doldurulması veya invajinasyonun tamamen ortadan kaldırılması şeklinde yapılabilir (105). İnvajinasyonun yerinde bırakılması, temizlik ve debridmanın daha zor hale gelmesi nedeniyle daha zor ve karmaşık bir tedaviye yol açarken kök yapısının sağlamlığına olumlu katkıda bulunur. İnvajinasyon, mine-sement birleşimine yakınsa koronal genişletme sırasında ortadan kaldırılabilir. Kökün orta üçte birlik kısmına veya apikal üçte birlik kısmından daha derine uzanıyorsa invajinasyonun ortadan kaldırılması zordur, ancak mikroskopik ve ultrasonik tekniklerin uygulanmasıyla bu mümkün hale gelmiştir (115).

Dens invaginatuslu dişlerin tedavisinde, dolgu materyali olarak kompozit rezin, amalgam veya cam iyonomer kullanıldığında bu materyallerin pulpada kronik irritasyon veya mikrosızıntıya neden olarak nekroza neden olabildiği görülmüştür. Biyouyumluluk ve antibakteriyel özelliklere sahip olan MTA, dens invaginatuslu dişlerde tedavinin başarı oranını arttırmak için tercih edilebilir (106).

2.2.8.3. Oehlers Tip III Dens İnvaginatusun Tedavisi

Tip III dens invaginatuslu dişlerin daha karmaşık bir kök kanal anatomisine sahip olması nedeniyle tedavileri daha zordur. Üç boyutlu görüntüleme, iç morfoloji hakkında ayrıntılı bilgi sağlamak ve tedaviye rehberlik etmesi açısından gereklidir. Klinik olarak tip III dens invaginatusa sahip birçok dişte pulpa hastalığı veya periapikal lezyon olduğu görülmüştür. Bu nedenle tedavi planlamasında pulpanın durumunun doğru değerlendirilmesi önemlidir. Pulpa vital ise invajinasyonun temizlenmesi ve doldurulması pulpa canlılığının korunmasında büyük önem taşımaktadır. Ana kanal ve invajinasyonlu kanalın her ikisi de enfekte ise her ikisinin de ayrı ayrı temizlenmesi ve doldurulması gerekir. Diş immatür ve apeksi genişse apeksifikasyon tedavisi önerilir. Pulpa revaskülarizasyonu bu tür vakalarda uygun diğer bir tedavi seçeneğidir (48,116).

Pulpa vitalse ve apikal periodontitis yoksa, tedavi sadece koruyucu-önleyici olmalıdır. Pulpal canlılığı korumak için invajinasyonun temizlenmesi, dezenfekte edilmesi ve doldurulması son derece önemlidir (46). Bununla birlikte, diğer tiplerden farklı olarak tip III dens invaginatus apikal periodontitisin pulpası vital olan bir dişte de görülebileceğine dikkat etmek önemlidir. Bu vakalarda periradiküler enflamatuar lezyonun nedeni, invajinasyonun bakteriyel enfeksiyonudur ve genellikle anormal anatomisine dikkat edilerek gerçek kök kanalları gibi temizlenmeli, şekillendirilmeli ve doldurulmalıdır. Böylelikle pulpa canlılığı korunabilir ve yalnızca invajinasyonun tedavi edilmesi periradiküler iyileşme ile sonuçlanabilir. Pulpa inflame ise hem gerçek kök kanalı hem de invajinasyon tedavi edilmelidir. Açık apeksli dişlerde, inflame pulpa için pulpotomi en iyi yaklaşım olabilirken, invajinasyon bir kök kanalı olarak tedavi edilmelidir (105).

Nekrotik pulpalı dişlerde ise ideal olarak kanal ve invajinasyon ayrı ayrı tedavi edilmelidir ancak, bazen preparasyon sırasında kaçınılmaz olarak bağlantı haline geçerler. Pulpa nekrozu ve apikal periodontiti olan tip III dens invaginatus vakaları tedavisi en zor olanlardır. Hem kök kanalının hem de invajinasyonun karmaşık anatomisi temizleme, şekillendirme ve dezenfeksiyonu çok zor hale getirir. Apeks olgunlaşmamışsa, kök gelişim aşamasına ve kök duvarı kalınlığına göre rejeneratif endodontik veya apeksifikasyon prosedürleri uygulanabilir. Kök kanal tedavisi, apeksifikasyon veya revaskülarizasyon gibi konservatif tedavilerin başarısız olması durumunda cerrahi tedavi endike olacaktır. Kasıtlı reimplantasyon tip III dens invaginatusun çok karmaşık formlarında rapor edilmiş olup endodontik tedavi, cerrahi veya kombine tedavi başarısız olduğunda son çare çekimdir (48).

2.3. Yapay Zekâ Nedir?

Yapay zekâ, genel olarak insan zekâsının performansına benzer görevleri yerine getirebilen bilgisayar sistemleri ve bu sistemlerin geliştirilmesi olarak tanımlanmaktadır. İnsana özgü olan algılama, öğrenme, düşünme, fikir yürütme, iletişim kurma, sorun çözme, çıkarım yapma ve karar verme gibi yüksek bilişsel fonksiyonları veya otonom davranışları sergileyebilen yapay bir işletim sistemidir (117).


Yapay zekâ, makinelerin insan davranışını taklit etmesini ve insan beyninin işlevsel bir modelini oluşturmasını sağlayarak öğrenme deneyimlerine dayalı karar almayı kolaylaştırma sürecini içerir. Yapay zekânın temeli, bilgisayar sistemlerini kullanarak öğrenme, bilgi toplama, analiz etme, bağlantıları belirleme ve buna göre karar verme yoluyla insan beynini ve davranışlarını taklit etmesine olanak tanıyan bir makineye dayanmaktadır (118).

Yapay zekâ kavramı, farklı bilim insanları ve araştırmacılar tarafından çeşitli şekillerde tanımlanmıştır. Genesereth ve Nilsson yapay zekâ kavramını, doğada bulunan varlıkların akıllı davranışlarını yapay olarak üretmeyi amaçlayan bir çalışma olarak tanımlamaktadır (119). Nabiyeve ise yapay zekâyı bir bilgisayarın öğrenme, yorumlama, anlama ve problem çözme gibi insanlara özgü komplike zihinsel süreçleri gerçekleştirme yeteneği olarak tanımlamaktadır. Yapay zekâ tanımlarında sıklıkla karşılaşılan “insan zekâsını ve becerilerini taklit etme yeteneği” vurgusu, makinelerin bunu ne kadar iyi başarabildiğinin değerlendirilmesi ihtiyacını da beraberinde getirmiştir (120,121).

2.3.1. Yapay Zekânın Tarihsel Gelişimi

Yapay zekânın temelini oluşturan ilk çalışma 1950 yılında Alan Turing tarafından kaleme alınan ve The Mind dergisinde yayımlanan ‘Hesaplama Makineleri ve Zekâ’ başlıklı makaledir. Alan Turing bu makalesinde ‘Makineler düşünebilir mi?’ sorusunu ortaya atmış ve bu sorunun daha iyi anlaşılabilmesi için ‘Turing testi’ adı verilen bir test önermiştir (122).

Turing testi, bir makinenin insan gibi düşünme yeteneğine sahip olup olmadığını test etmek için kullanılan bir yöntemdir (Şekil 2.4). Turing tarafından geliştirilen bu testte sorgulayıcılar hem bir insana hem de monitörün arkasında yer alan bir makineye sorular sorarlar. Bu testte yanıtların doğasına göre yanıtların bir insandan mı yoksa bir makineden mi geldiğini ayırt etmek amaçlanmaktadır. Bu test, yapay zekânın seviyesini değerlendirmek için önerilen ilk yaklaşımlardan biridir ve yapay zekâ tartışmalarında önemli bir kavramdır (122,123).



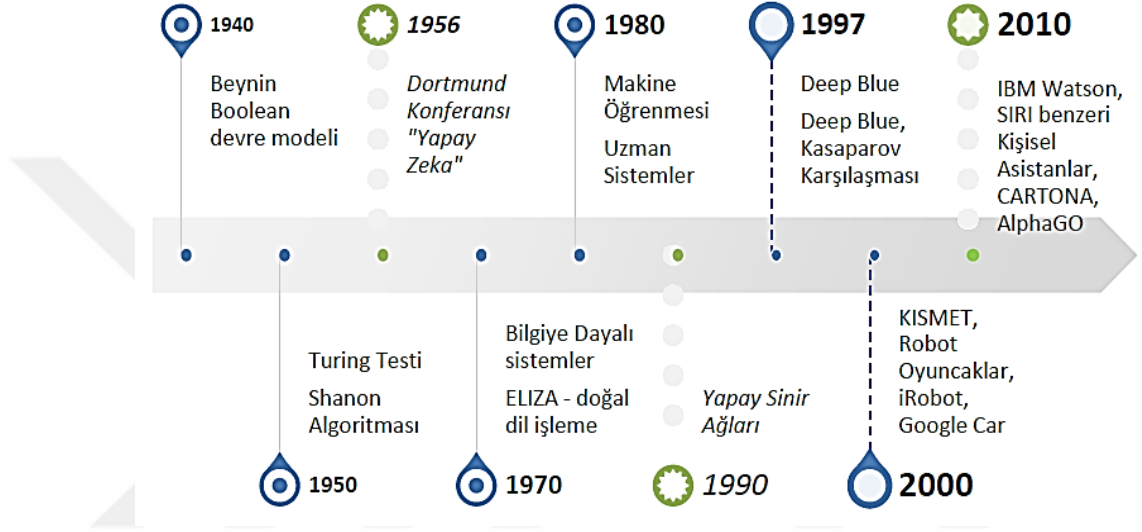
Şekil 2.4: Turing Testi (124)

Makinelerin insanlar gibi düşünmesini ve hareket etmesini sağlamayı amaçlayan yapay zekâ alanında geçmişten günümüze kadar çok sayıda kişi ve kuruluş araştırma yapmış ve çalışmalarını sürdürmüştür (125). Köklerini matematik, psikoloji, dil bilimi ve bilgisayar bilimi gibi çeşitli bilimsel alanlara dayandıran "Yapay Zekâ" terimi ilk olarak 1956 yılında Dartmouth'da düzenlenen bir konferansta ortaya çıkmıştır (125). Bu konferansta yapay zekâ terimini dile getiren ve yapay zekâ teriminin yaratıcısı olarak bilinen John McCarthy, yapay zekâyı, "akıllı makineler yapma bilimi ve mühendisliği" olarak tanımlamıştır (126).

1960'lara gelindiğinde, bilgisayarların bilgi saklama ve işlem yapabilme yetenekleri gelişmiştir. Bu dönemde Simon ve Newell 'GPS-Genel Problem Çözücü'yü, Joseph Weizenbaum ise 'ELIZA' adlı ilk doğal dil işleme programını geliştirdi (127). 1980'lerde bilgisayarların bilgi saklama ve işleme kapasitelerinin yanı sıra, bilgiler arası ilişki kurabilme yetenekleri de gelişti. Bu dönemde John Hopfield ve David Rumelhart, derin öğrenme tekniklerini yapay zekâyı kazandırdı. Derin öğrenme, bilgisayarların daha önce sakladığı bilgileri yeni durumlarda kullanarak öğrenme yeteneklerini geliştirdi. Aynı dönemde Edward Feigenbaum, uzman sistemler adı verilen ve insan karar mekanizmalarını taklit eden programlar geliştirdi (127,128).

1990'larda yapay sinir ağları, insan beynini taklit eden ve birbirinden bağımsız bilgi işleme yapıları olarak yapay zekâyı yeni bir boyut kazandırdı. IBM (International

Business Machines)' nin Deep Blue programının, 1997 yılında dünya satranç şampiyonu Gary Kasparov'u yenmesi toplumda akıllı makineler konusundaki farkındalığı artırdı. Yine aynı dönemde Dragon Systems, Windows'ta kullanılan ilk konuşma tanıma yazılımını piyasaya sürdü. MIT laboratuvarlarında 2001 yılında geliştirilen 'Kismet' adlı robot, insan mimiklerini kullanabilen, sosyalleşebilen ve öğrenebilen bir makine olarak dikkat çekti (Şekil 2.5) (127,128).

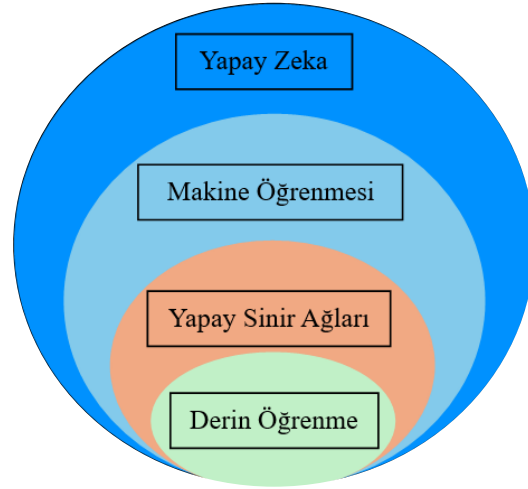


Şekil 2.5: Yapay zekânın tarihsel gelişimi (127)

Günümüzde ise yapay zekâ sağlık, eğitim, ulaşım, bankacılık, teknoloji ve eğlence gibi birçok alanda devrim niteliğinde yenilikler sunarak hayatımızı daha verimli, güvenli ve konforlu hale getirmektedir. Gelecekte bu teknolojinin daha da gelişmesiyle birlikte, yeni kullanım alanlarının ortaya çıkması ve mevcut alanlardaki etkisinin daha da artması beklenmektedir.

2.4. Makine Öğrenimi

Makine öğrenimi, bilgisayar sistemlerinin verilerden öğrenme, kalıpları tanıma ve karar verme yeteneğini geliştiren bir yapay zekâ alanıdır (Şekil 2.6). Makine öğrenimi sayesinde yapay zekâ insanların düşünme, kendini geliştirme ve geçmiş deneyimlerden öğrenme yeteneklerini kazanabilir (129).



Şekil 2.6: Yapay zekâ ve temel kavramlar arasındaki ilişki (130)

Makine öğrenimi, bilgisayarın kendi verilerinden ve geçmiş deneyimlerinden öğrenmesini sağlayan algoritmaların geliştirilmesiyle ilgilenir. Bu yöntemde makine, eğitim verileri olarak da bilinen mevcut veri setini analiz eder ve algoritmaların yardımıyla verilen girdi üzerinden olası çıktıyı tahmin eder. Ne kadar çok veri sağlanırsa performans veya tahmin o kadar iyi olur. Başka bir deyişle veri ve verimlilik arasındaki ilişki, makinenin giderek daha fazla veri toplayarak verimliliğini artırabilmesidir (131).

2.4.1. Makine Öğreniminin Sınıflandırılması

Makinenin aldığı öğrenme sinyalinin veya yanıtının doğasına bağlı olarak makine öğrenimi aşağıdaki sınıflara ayrılabilir:

2.4.1.1. Denetimli Öğrenme

Denetimli öğrenme, bilgisayar algoritmalarının belirli bir çıktı için etiketlenmiş girdi verileri üzerinde eğitildiği, yapay zekâ oluşturmaya yönelik bir yaklaşımdır. Bu öğrenme yönteminde sistemin eğitilmesinde bir danışmana ihtiyaç vardır. Model, giriş verileri ile çıkış etiketleri arasındaki temel kalıpları ve ilişkileri tespit edene kadar eğitilir ve daha önce hiç görülmemiş veriler sunulduğunda doğru etiketleme sonuçları vermesini sağlar (6,132).

2.4.1.2. Denetimsiz Öğrenme


Bu yöntemde, makinenin kendisini herhangi bir denetleyici olmadan eğitmesi gerekir, yani girişte sağlanan veriler etiketlenmez veya sınıflandırılmaz. Algoritma, verilen veriler arasındaki benzerliklerin derecesini araştırarak ve verilen problem için uygun çıktıyı bularak kendini eğitmelidir. Algoritma, istenen çıktıyla ilişkilendirilebilecek verilerin iyileştirilmesine yardımcı olur (6).

2.4.1.3. Takviyeli (Pekiştirmeli) Öğrenme

Bu yöntem genellikle geri bildirim dayalı bir öğrenme yöntemidir. Bu yöntemde, makineye her doğru eylemi için bir ödül, her yanlış eylemi için ise bir ceza verilir. Böylece makine, geçmiş performanslarını analiz ederek kendi kendine öğrenir. Algoritmanın amacı maksimum ödül puanı elde etmektir. Takviyeli öğrenmeye örnek olarak robotik bir köpeğin kendi hataları ve performanslarıyla öğrenmesi, bilgisayarın kendi başına video oyunları oynaması gösterilebilir. Makine öğrenimi algoritması, tıbbi teşhis, görüntü işleme, web arama motorları, fotoğraf etiketleme uygulamaları, finans ve pazarlama sektörü, hava tahmini ve daha birçok alanda yaygın olarak kullanılmaktadır. Bu yöntemin avantajı, çıktıyı bulmak için uyguladığı tekrarlayan süreç ve kendi kendine öğrenme yöntemleridir (131).

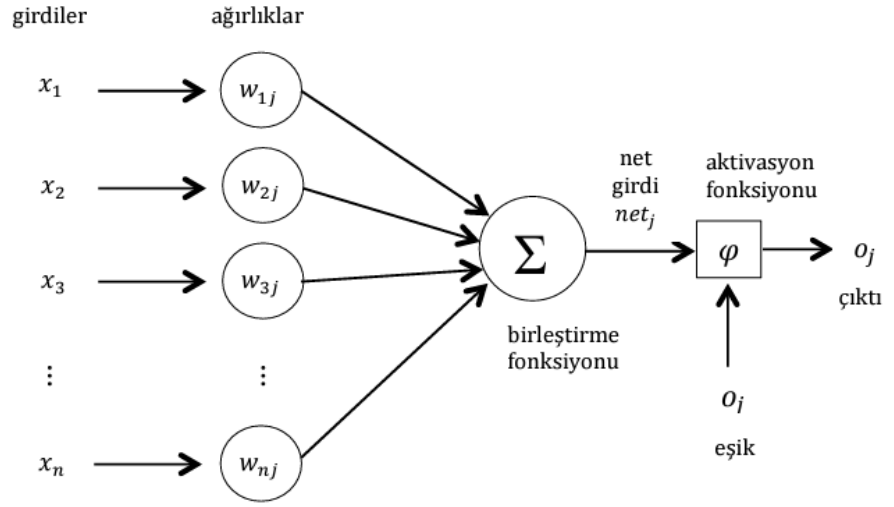
2.5. Yapay Sinir Ağları

İnsan beyninin temel işlem birimi olan nöronlar, sinir sisteminin en basit yapı taşlarıdır (Şekil 2.7). Yapay sinir ağları, bu nöronların işlevsel ve yapısal özelliklerine benzer şekilde tasarlanmıştır. Biyolojik sinir sistemini matematiksel bir model olarak temsil eden yapay sinir ağları, bilgi depolama, işleme ve kullanma kapasiteleriyle biyolojik sinir sistemini taklit eder ve insan gibi karar verebilen zeki sistemler oluşturmayı amaçlar (121,133).



Şekil 2.7: Biyolojik nöronun yapısı (134)

Biyolojik sinir hücrelerine karşılık olarak yapay sinir ağları, yapay sinir hücrelerinden oluşur (Şekil 2.8). Bu yapay sinir hücrelerinin temel bileşenleri; girdiler, ağırlıklar, toplama fonksiyonu, transfer (aktivasyon) fonksiyonu ve çıktılardır (135).



Şekil 2.8: Yapay nöronun yapısı (121)


Yapay sinir hücreleri katmanlar halinde birleşerek yapay sinir ağlarını oluşturmaktadır. Bu katmanlar; girdi katmanı, çıktı katmanı ve aralarındaki gizli katmanlardan meydana gelir. Her bir katman nöronlardan oluşur. Girdi ve çıktı katmanlarındaki nöron sayısı, bağımsız ve bağımlı değişkenlere bağlı olarak belirlenirken, gizli katman sayısı ve her bir gizli katmandaki nöron sayısı kullanıcı tarafından en iyi performansı elde edecek şekilde ayarlanır (135).

Girdi katmanı, temel olarak ağın ilk katmanı ve ağın giriş katmanıdır. Çıktı katmanı, ağın son katmanı olup ağın çıkışını üretir. Ağdaki süreç katmanları da gizli katmanlardır. Gizli katman, gelen veriler üzerindeki belirli görevleri gerçekleştiren ve bu görevler sonucunda üretilen çıktıları bir sonraki katmana aktarır (135).

Yapay sinir ağ modelleri dört gruba ayrılabilir. Bu modeller katman sayısına göre tek katmanlı ve çok katmanlı, sinirler arasındaki bağlantıların yönüne göre ileri ve geri beslemeli ağlar olarak sınıflandırılabilir (133).

2.5.1. Tek Katmanlı Algılayıcılar

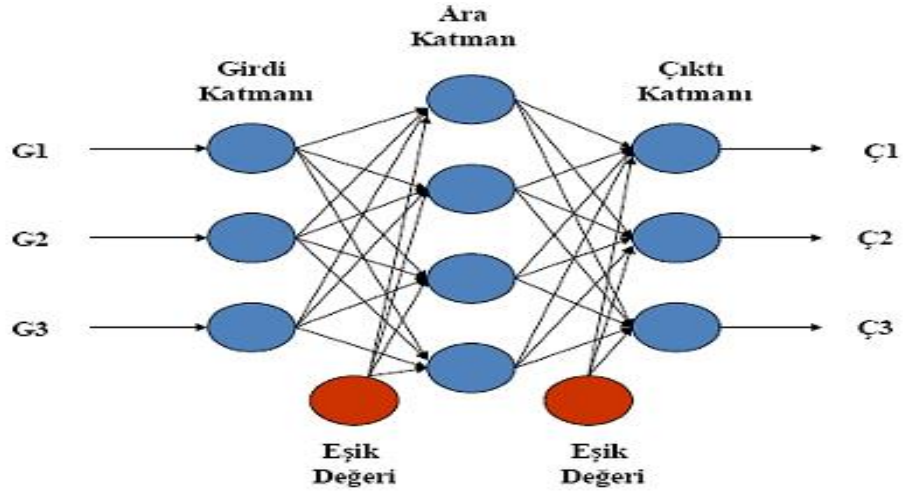
Tek katmanlı algılayıcılar, sadece girdi ve çıktı katmanlarından oluşur ve çıktı fonksiyonu doğrusaldır (Şekil 2.9). Bu algılayıcılar basit problemleri ve doğrusal ilişkileri çözmede etkilidir (133,135).



Şekil 2.9: Tek katmanlı algılayıcı modelinin yapısı (133)

2.5.2. Çok Katmanlı Algılayıcılar

Yapay sinir ağlarının en temel ve yaygın biçimlerinden birisi olan bu yapı, insan beyninin bilgi işleme yöntemini taklit etmeyi amaçlayan matematiksel bir modeldir (Şekil 2.10). Yapı olarak, doğrusal olmayan aktivasyon fonksiyonu olan ve birden çok nöronun birbirine bağlandığı ağlardır. Birbirine bağlı yapay sinir hücrelerinden oluşan çok sayıda katmana sahiptir (135).



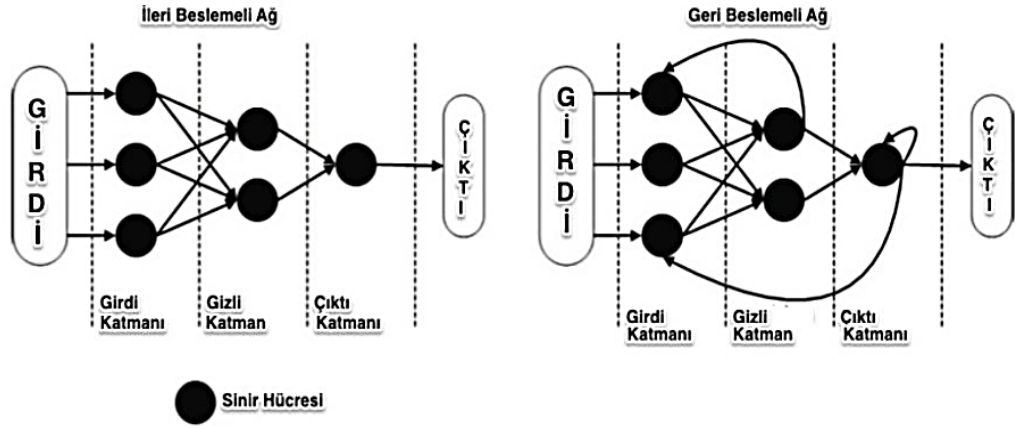
Şekil 2.10: Çok katmanlı yapay sinir ağının genel yapısı (136)

2.5.3. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağları, geliştirilen ilk yapay sinir ağı türüdür ve evrişimli sinir ağları ve tekrarlayan sinir ağları gibi benzerlerinden daha basittir. Bu ağda bilgi, giriş katmanından varsa gizli katmanlara ve çıkış katmanlarına doğru yalnızca tek bir yönde olacak şekilde hareket eder (Şekil 2.11). İleri beslemeli ağlarda herhangi bir döngü veya tekrar yoktur (133,135).

2.5.4. Geri Beslemeli Yapay Sinir Ağları

Bu ağ yapısında ileri beslemeli ağ yapılarının aksine bir nöronun çıktısı sadece kendinden sonraki nöron katmanına girdi olarak verilmez. Bu ağlarda, ara katmanlardaki çıktılar ve çıkış katmanı önceki katmanları tekrar besleyebilir (Şekil 2.11). Bu özelliği sağlayan bağlantıların düzenleniş biçimine bağlı olarak, aynı yapay sinir ağıyla çeşitli davranışlar ve yapılarda geri beslemeli yapay sinir ağları oluşturulabilir. Geri beslemeli ağlar özellikle danışmansız öğrenme ile çözümlenen problemler için kullanılabilir (133,135).



Şekil 2.11: İleri ve geri beslemeli ağ yapısı örnekleri (137)

2.6. Derin Öğrenme

Derin öğrenme, çok katmanlı yapay sinir ağlarını kullanarak karmaşık görevleri gerçekleştirebilmek için tasarlanmış olan makine öğrenimi yöntemlerinden biridir. Derin öğrenme, geleneksel makine öğrenimi yöntemlerinden farklı olarak ses, video resim ve metinlere ait verilerden otomatik olarak öğrenebilmektedirler. Büyük veri kümelerinden öğrenebilen ve karmaşık görevleri gerçekleştirmek için kullanılacak yüksek düzeyde soyutlama elde edebilen yapay sinir ağlarının çok katmanlı yapısını oluşturur (138).

Derin öğrenme, dönüşüm ve özellik çıkarma gibi doğrusal olmayan katmanları kullanır. Her ardışık katman, bir önceki katmanın çıktısını girdi olarak alır. Temel olarak derin öğrenme, bir sinir ağı aracılığıyla veriler arasındaki karmaşık ilişkileri öğrenme yeteneğiyle bilinir ve bu nedenle genellikle büyük veri kümeleri ve yeterli hesaplama kaynakları gerektirir. Derin öğrenmenin ses ve görüntü tanıma, doğal dil işleme ve diğer karmaşık görevlerde başarılı olması büyük veri kümelerine ve güçlü bilgi işlem kaynaklarına dayanmaktadır (138–140).

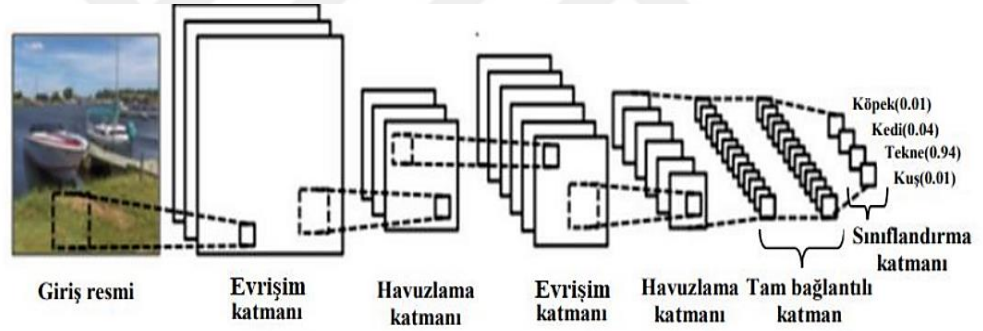
2.7. Derin Öğrenme Mimarileri

2.7.1. Evrişimli (Konvolüsyonel) Sinir Ağları (CNN)

Evrişimli Sinir Ağları (CNN), çoğunlukla görsel veri kümelerinin analizinde kullanılmak üzere özelleşmiş bir tür derin öğrenme mimarisidir. LeCun ve arkadaşları

tarafından gradyan temelli bir yaklaşım sunularak tanıtılan bu yapıya ‘evrişimli (konvolüsyonel) sinir ağı’ adı verilmiştir (141). Çok katmanlı olan bu sinir ağı, birden fazla evrişim katmanı, tam bağlantılı katman, aktivasyon katmanı, sınıflandırma katmanı, havuzlama katmanı ve ek katmanlar içerir. Katmanların her biri kendine özel işlevini yerine getirerek sınıflandırma katmanında sonucun üretilmesini sağlar (142).

CNN'de katmanlar, konvolüsyon veya alt örnekleme gibi belirli bir işi gerçekleştirmek için kullanılır ve ardından ağı, bir çıktı üretmek için tam bağlantılı bir derin mimariye bağlanır. Her bir konvolüsyon ve alt örnekleme katmanında, giriş görüntülerinden daha üst düzey özellikler çıkarılır ve çıktı daha doğru hale gelir. Yani derin bir ağı olarak, ilk katmanlar özellikleri tanır ve sonraki katmanlar, bu özellikleri girdinin daha üst düzey nitelikleri olarak yeniden birleştirir (143). Örnek bir CNN mimarisi Şekil 2.12'de gösterilmektedir.



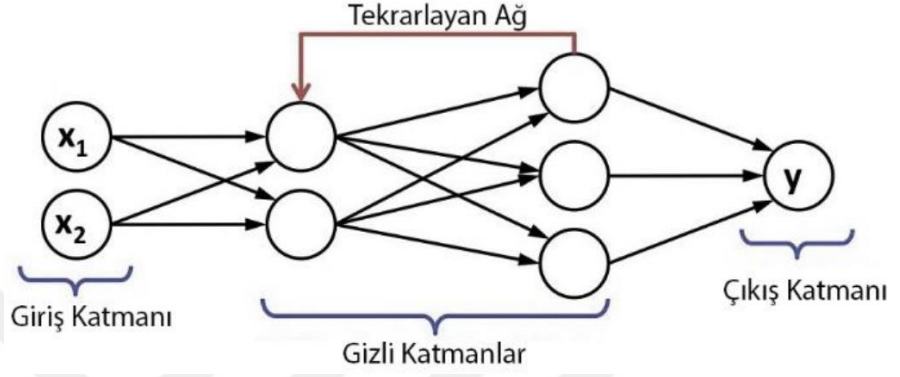
Şekil 2.12: CNN katmanları (145)

CNN'ler biyolojik süreçlerden ilham alır ve beynin görsel korteksinde bulunan sinirsel bağlantıyı taklit etmek için tasarlanmıştır. Görüntü tanıma, tıbbi görüntü analizi, sınıflandırma ve doğal dil işleme (NLP) alanlarında geniş bir uygulama alanına sahiptir (144).

2.7.2. Tekrarlayan Sinir Ağı (RNN-Recurrent Neural Network)

Tekrarlayan sinir ağları, ardışık veriler için bir önceki çıktının bir sonraki çıktıyı tahmin etmesi için kullanıldığı ağlardır ve bu tekrarlayan sinir ağlarının içinde döngüler bulunmaktadır (Şekil 2.13). Çıktının tahmin edilebilmesi için gerekli bilgilerin depolanmasını sağlayan döngüler ise gizli nöronlar içinde bulunmaktadır. RNN'lerin bu yapısı, karmaşık sinyalleri uzun zaman aralıkları boyunca depolamasını, hatırlamasını

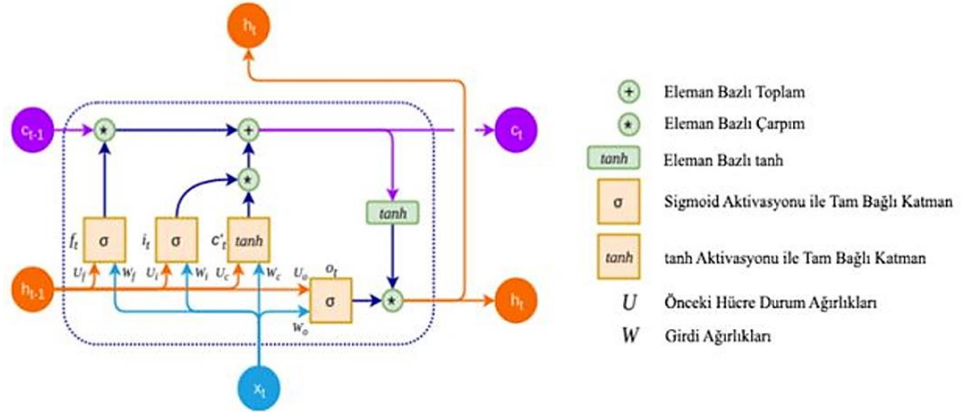
ve işlemlerini sağlar. RNN'ler, mevcut zaman adımında giriş dizisini çıkış dizisiyle eşleştirebilir ve bu dizileri bir sonraki zaman adımında tahmin edebilir. Bu yaklaşım, doğal dil işleme, konuşma tanıma gibi önceki girdiler hakkında bilgi gerektiren konularda oldukça faydalıdır (146).



Şekil 2.13: Tekrarlayan sinir ağı yapısının modeli (146)

2.7.3. Uzun-Kısa Süreli Bellek Ağları (LSTM- Long Short-Term Memory)

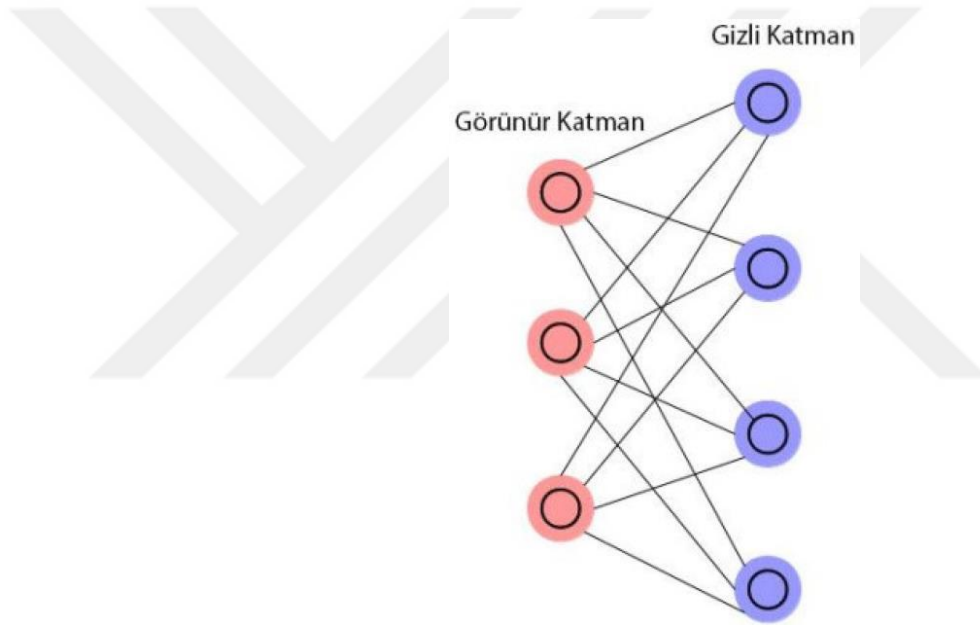
LSTM (Uzun Kısa Süreli Bellek) ağları, uzun vadeli bağımlılıkları öğrenebilen özel bir tekrarlayan sinir ağı tipidir. Schmidhuber ve Hochreiter tarafından tanıtılarak geliştirilen bu ağlar, bilgileri uzun süre hatırlamak için tasarlanmıştır (Şekil 2.14). LSTM modelleri, zamansal bağımlılıkları öğrenebilen ve karmaşık çok değişkenli dizileri doğru bir şekilde modelleyebilen ağlardır. Bu ağlar aynı zamanda, geçmiş bilgileri mevcut bilgilere dönüştürmenin ve gelecekteki bilgileri tahmin etmenin etkili bir yoludur (147).



Şekil 2.14: Uzun-kısa süreli bellek ağlarının yapısı (148)

2.7.4. Kısıtlı Boltzmann Makinesi (RBM-Restricted Boltzmann Machine)


Hinton ve arkadaşları tarafından, 1986 yılında Boltzmann Makinesinin farklı bir versiyonunu tasarlanarak geliştirilmiş sinir ağıdır. Bu sinir ağı, bir girdi katmanı ve bir gizli katmandan oluşan iki katmanlı bir yapıya sahiptir. Katmanlar arasındaki düğümler arasında bağlantı bulunmaz. Dolayısıyla katmanlar arası iletişim bulunmamaktadır (Şekil 2.15). Bu nedenle "kısıtlı Boltzmann makineleri" olarak adlandırılır. Sınıflandırma, regresyon, özellik öğrenimi, boyut azaltma, modelleme gibi alanlarda kullanılabilir (149,150).



Şekil 2.15: Kısıtlı Boltzmann Makinesi (146)

2.7.5. Derin İnanç Ağları (DBN-Deep Belief Network)

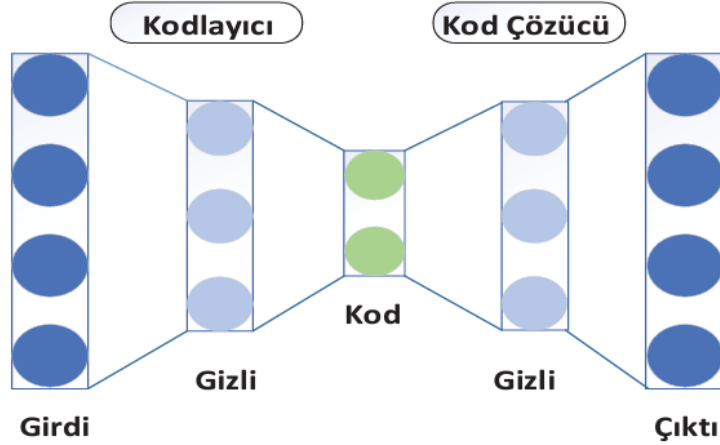
Derin inanç ağları (DBN), her bir alt ağı gizli katmanının bir sonraki RBM'nin görünür katmanına bağlandığı RBM'lerin bir birleşimidir. Yönsüz bağlantılar, yalnızca üstteki iki katmanda bulunurken, alt katmanlar yönlendirilmiş bağlantılara sahiptir (Şekil 2.16). Hem denetimli hem de denetimsiz şekilde kullanılabilir ancak, eğitim süreci oldukça yavaş olabilmektedir (146).



Şekil 2.16: Derin inanç ağı modeli (146)

2.7.6. Derin Oto-Kodlayıcılar (Deep Auto Encoder)

Derin öğrenme mimarilerinden biri olan derin oto-kodlayıcılar denetimsiz öğrenme algoritmalarının kullanıldığı sistemlerdir (Şekil 2.17). Derin oto-kodlayıcılar, problem çözümünde gerekli olan öznelik kümesinin veriden otomatik olarak çıkartılması ve veri kümesini sıkıştırılarak en az kayıpla veri boyutu sayısının azaltılması amacıyla ortaya atılmış ağlardır. Yüz ve ses tanıma, sinyal gürültüsü temizlemede kullanılabilir (151).



Şekil 2.17: Derin oto-kodlayıcı yapısı (152)

2.8. Derin Öğrenme Modelleri

2.8.1. LeNet

İlk CNN ağı Yann LeCun tarafından 1988 yılında ortaya atılan LeNet isimli mimaridir. Bu ağda alt katmanlar ardı sıra yerleştirilmiş evrişim ve maksimum

havuzlama katmanlarından oluşur. Bu mimari posta kodları gibi rakamları içeren karakter tanıma gibi görevler için geliştirilmiş ve özellikle rakam tanıma alanında kullanılan veri tabanları ile birlikte kullanılarak başarılı sonuçlar elde etmiştir. Bu sayede LeNet, konvolüsyonel sinir ağlarının temelini oluşturarak derin öğrenme modellerinin geliştirilmesinde katkıda bulunmuştur (142).

2.8.2. AlexNet

AlexNet, 2012 senesinde düzenlenen ImageNet isimli görsel tanıma yarışmasında birincilik kazanan derin öğrenme mimarisi olup örüntü tanımada hata oranını %26'dan %15'e kadar indirmeyi başarmıştır. AlexNet'in bu büyük başarısı, derin öğrenme araştırmalarının popüler hale gelmesinde önemli ölçüde katkı sağlamıştır. Bu mimari, geniş ve derin evrişimli sinir ağlarının önemini vurgulayarak önceki yöntemlerden daha iyi bir performans sergilemiş ve derin öğrenme alanında bir dönüm noktası olmuştur (151).

2.8.3. VGG Net

VGGNet, 2014 ImageNet yarışmasında %89 başarı oranı elde eden grafik işlem birimi (GPU) destekli bir derin öğrenme modelidir. Diğer modellere kıyasla göze çarpan bir özelliği, bir havuzlama katmanının ardından ikili veya üçlü bir evrişim katmanının gelmesidir (135).

2.8.4. Google Net

GoogleNet, 2014'te düzenlenen ImageNet yarışmasını %5,7'lik hata oranı ile yüksek bir başarı göstererek kazanmıştır. Kompleks bir yapıya sahip olan bu mimari Inception modülü ile farklı boyutlarda filtreleme yaparak önceki derin öğrenme mimarilerinden ayrılmaktadır. Inception modülü, farklı boyutlardaki filtreleri tek katmanda birleştirerek, daha az katmanda daha fazla bilginin işlenmesini sağlar. Bu da GoogleNet'in daha hızlı ve verimli bir şekilde eğitilmesini sağlamaktadır (153).

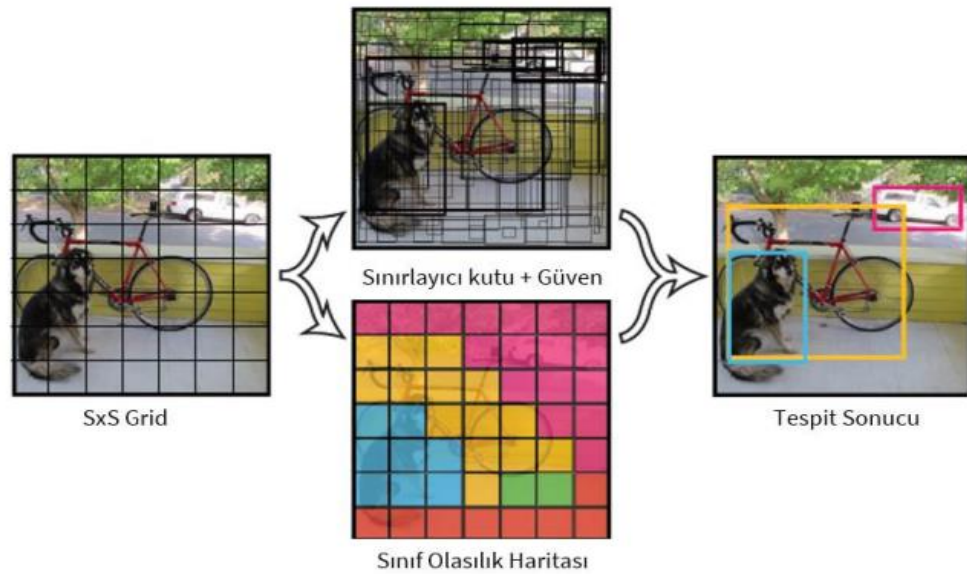
2.8.5. ResNet

Microsoft tarafından geliştirilen ResNet, residual bloklardan oluşan çok katmanlı ve derin mimarisi sayesinde 2015'te yapılan ImageNet yarışmasında %3,6'lık hata

oraniyla birinci olmuştur. Residual bloklar bilgiyi önceki katmanlardan sonraki katmanlara aktararak öğrenmeyi stabilize eder, bu sayede daha derin ağlar oluşturmasına ve daha yüksek doğruluk elde edilebilmesine olanak tanır. ResNet, nesne tespiti, görüntü sınıflandırma ve tanıma gibi birçok alanda kullanılabilir (154).

2.8.6. YOLO

YOLO (You Only Look Once), özellikle nesnelerin tespiti için tasarlanmış hızlı ve yüksek performanslı, tek aşamalı bir modeldir. Redmon ve arkadaşları tarafından 2015 yılında tanımlanan bu model nesne tespitinde en çok kullanılan derin öğrenme modellerindendir (155). YOLO, bir görüntüyü eş zamanlı olarak analiz ederek bölgeleri tespit eder, sınıflandırır ve gereksiz tekrarları ortadan kaldırır. YOLO'nun temel farkı, diğer nesne algılama yöntemlerine göre çok daha hızlı çalışmasıdır. Diğer derin öğrenme yöntemleri genellikle görüntü üzerinde nesnelerin bulunma ihtimali olan alanları tespit edip daha sonra sınıflandırıcılarla nesneleri tespit etmeye çalışırken, YOLO aynı işlemi tek seferde yapabilmektedir. Algoritma, görüntüyü küçük bölgelere böler ve her bölgeyi analiz eder (Şekil 2.18). Her bölge için sınıflandırma ve lokalizasyon işlemlerini eş zamanlı olarak gerçekleştirir. Bu da nesne tespitinin ve sınıflandırılmasının tek bir işlemle gerçekleştirilmesine olanak tanır (156).



Şekil 2.18: YOLO nesne tespit aşamaları(156)

YOLO mimarisi hem hız hem de doğruluk açısından dengeli sonuçlar elde etmek için tasarlanmıştır. YOLO ailesinin YOLOv2 (2017), YOLOv3 (2018), YOLOv4 (2020), YOLOv5 (2020), YOLOv6 (2022), YOLOv7 (2022) ve YOLOv8 (2023) isimleriyle bilinen birçok farklı modeli bulunmaktadır (157).

2.9. Derin Öğrenme Kütüphaneleri

Derin öğrenme yapıları, gelişmiş programlanmış arayüzlerini kullanarak yapay sinir ağlarının tasarlanmasına, eğitilmesine ve doğrulama yapabilmesine olanak sağlamaktadır. Bu amaçla, derin öğrenme modellerine dayanan gerçek zamanlı uygulamalar için kullanılan çeşitli araçlar ve kütüphaneler mevcuttur (135,158).

2.9.1. Caffe2

Caffe2, Python tabanlı bir uygulama kullanarak bu modelleri daha kolay tanımlayabilen derin bir öğrenme çerçevesidir. Kullanıcılar, görselleştirmeyi kolaylaştıran Python ve doğrudan temel oluşturan C++ uygulamalarının kullanılmasıyla yüksek seviyeli ve etkileyici işlem kombinasyonlarını kullanarak esnek modelleri oluşturma imkânına sahip olmaktadır (135,159).

2.9.2. TensorFlow

TensorFlow, sayısal hesaplamalar için açık kaynak kodlu bir yazılım kütüphanesine sahip olan ve veri akış grafiklerini kullanan derin öğrenme yazılımıdır. Grafikteki düğümler matematiksel işlemleri temsil etmek için kullanılırken, grafiğin kenarları çok boyutlu veri dizilerini veya tensörleri temsil etmek için kullanılır (135).

2.9.3. Torch

Ses ve görüntü işleme, resim, video formatları üzerinde çalışabilme özelliklerine sahip Torch kütüphanesi, Python ve Lua programlama dilleriyle de desteklenmektedir. Karmaşık sorunları basitleştirip çözümünü ilgili algoritmayı hızlı ve esnek olarak hazırlayabilmektedir (159).

2.9.4. Theano

Theano, MILA LAB tarafından geliştirilmiş ve çok boyutlu diziler dahil

matematik ifadelerini etkili bir şekilde tanımlamaya ve değerlendirmeye olanak sağlayan, matematik işlemlerini kolaylaştıran bir Python kütüphanesidir (159).

2.9.5. Keras

Keras, derin öğrenme modelleri oluşturmak için Python ile yazılmış, TensorFlow üzerinde çalışan bir derin öğrenme kütüphanesidir. Francois Chollet tarafından geliştirilen Keras, ağ modellerinin daha hızlı uygulanmasını sağlar (159).

2.9.6. PyTorch

Matematiksel işlemler için Python tarafından desteklenen Tensor hesaplamalar yapabilen, grafik işlem biriminin daha hızlı çalışmasını sağlayan güçlü bir grafik işleme birimine (GPU) sahip, Python tabanlı bir derin öğrenme paketidir. PyTorch'un dinamik hesaplamalı grafiklere yönelik desteği, modellerde gerçek zamanlı ayarlamalar yapılabilmesine olanak sağlar (135,159).

2.10. Diş Hekimliğinde Yapay Zekâ

Yapay zekâ, günümüzde günlük yaşamın neredeyse her alanına nüfuz ederek insan yaşamının bir parçası haline gelmeye başlamıştır. Diş hekimliği, teknolojinin en yaygın kullanıldığı alanlardan biri olduğu için teknolojideki gelişmelere ve yapay zekâ uygulamalarının adaptasyonuna oldukça açık bir alandır. Yapay zekânın teşhis, karar verme, tedavi planlama ve sonuç tahminini kapsayan bir dizi uygulama sunması sayesinde diş hekimliği alanında kullanımı artmaktadır. Son yıllarda yapay zekâ uygulamaları, çürük teşhisi ve çeşitli patolojilerin tespitinden robotik cerrahi ve dental implant yapımına kadar diş hekimliğinde farklı alanlarda yaygın olarak kullanılmaktadır. Yapay zekâ uygulamaları, diş hekimliği alanında iki boyutlu radyografiler (panoramik, periapikal, bitewing, sefalometrik, grafiler), üç boyutlu radyografiler (KIBT) ve intraoral fotoğraflar kullanılarak birçok çalışmada gerçekleştirilmiştir (160).

Yapay zekâ, diş hekimliğinde en iyi tedavi sonuçlarına ulaşmak ve en yüksek kalitede hasta bakımını sağlamak için gerekli olan teşhis sürecini daha doğru ve verimli

hale getirmek amacıyla kullanılmaya başlanmış ve bu alanda önemli gelişmeler görülmüştür (130). Yapay zekâ, diş hekimlerinin teşhis koyma ve en iyi tedavi seçeneğine karar verme aşamasında karar destek mekanizması olarak rehberlik ederek daha iyi performans göstermelerini sağlamak için kullanılabilir (161,162). Ayrıca hasta takibinde ve tedavinin değerlendirilmesinde önemli rol oynayabilir. Hastaların diş sağlığına ilişkin elektronik verilerle genel sağlık durumlarının analiz edilmesi sayesinde, diş hekimleri hastaların diş ve genel sağlık durumlarını daha iyi izleyebilir, teşhis doğruluğunu artırabilir ve tedavi sürecini optimize edebilir (163).

2.11. Çocuk Diş Hekimliğinde Yapay Zekâ

Son yıllarda diş hekimliğinde yapay zekânın geliştirilmesi ve kullanılması konusunda önemli ilerlemeler kaydedilmiştir. Yapay zekâ uygulamaları, makine öğrenimi algoritmaları, sinir ağları dahil olmak üzere çok çeşitli teknolojileri içerir. Bu teknolojiler patolojilerin, anomalilerin erken belirtilerini dikkate değer bir doğrulukla tespit edebilen yapay zekâ tabanlı görüntüleme sistemleri gibi gelişmiş teşhis araçlarının geliştirilmesine olanak sağlar (164). Ayrıca yapay zekâ tabanlı tahmine dayalı değerlendirme, hastaların bireysel ihtiyaçlarına göre uyarlanmış erken müdahale ve önleyici tedavilere imkan sağlayabilir (165).

Çocuk diş hekimliğinde yapay zekâ çalışmaları temel olarak plak, çürük, fissür örtücü, meziodens ve süpernümerer dişlerin tespiti, süt ve genç daimi dişlerin tespiti, kronolojik yaş tespiti, anatomik landmark tespiti konularına odaklanmış olup sonuçları umut vaat edicidir (7). Yetişkin tanı ve tedavisindeki gelişmelerin, pedodonti alanına uygulanmasının yanı sıra ağrı kontrolü, davranış yönlendirme teknikleri, ebeveyn ve hasta eğitimi gibi alanlarda da yapay zekâ uygulamaları geliştirilebilir (166). Çocuk diş hekimliğinde yapay zekâ uygulamalarına yönelik bazı çalışmaların detayları Tablo 2.2'de gösterilmektedir.

Tablo 2.2: Çocuk diş hekimliğinde yapay zekâ uygulamaları ile ilgili bazı çalışmalar

YAZAR	KULLANILAN YAPAY ZEKÂ ALGORİTMASI	VERİ SETİNİN BÜYÜKLÜĞÜ	SONUÇLAR
Süt ve Daimi Dişlerinin Tespiti ve Numaralandırılması			
Kılıç ve ark. (2021) (167)	Faster R-CNN, Inception v2	421 panoramik radyografi	Modelin duyarlılık, kesinlik, F1 skoru sırasıyla 0,9804, 0,9571 ve 0,9686 bulunmuştur.
Kaya ve ark. (2022) (168)	YOLOv4	4518 panoramik radyografi	Modelin kesinlik değeri %94,16 ve F1 skoru 0,90 olup yüksek anlamlılık düzeyine işaret etmektedir.
Beşer ve ark. (2024) (169)	YOLOv5	3854 panoramik radyografi	Diş tespiti için duyarlılık, kesinlik, F1 skoru ve ortalama kesinlik-0.5 (mAP-0.5) değerleri sırasıyla 0,99, 0,99, 0,99 ve 0,98'dir.
Yaş Tahmini			
Bunyarit ve ark. (2020) (170)	ANN	1015 panoramik radyografi	Çok katmanlı yapay sinir ağları (ANN-MLP) kullanan bu yeni tahmin modeli, yüksek doğrulukta dental yaş tahminiyle sonuçlanmıştır.
Zaborowicz, M. ve ark. (2022) (171)	ANN	619 panoramik radyografi	Önerilen modelin kalite parametrelerinde ortalama mutlak hata (MAE) hatası 2,34 ile 4,61 arasında bulunmuştur.
Lee ve ark. (2022) (172)	Makine Öğrenmesi	471 panoramik radyografi	Çalışma sonucunda beş farklı makine öğrenmesi modeli için 0,85 ile 0,88 arasında AUC (eğri altındaki alan) değerleri elde edilmiştir.
Baydoğan ve ark. (2022) (173)	AlexNet	627 panoramik radyografi	Bu çalışmada AlexNet mimarisi kullanılarak %84 doğruluk, %85 F1 skoru ve %76 duyarlılık değerlerine ulaşılmıştır.
Aljameel ve ark. (2023) (174)	Xception, VGG16, DenseNet121, ResNet50	529 panoramik radyografi	Çalışmanın sonuçları, 6-11 yaş grubu için 1.417 hata oranıyla Xception modelinin en iyi performansa sahip olduğunu göstermiştir.

Tablo 2.2. (devamı)

Mesiodens/Süpernümerer Diş Tespiti			
Kuwada ve ark. (2020) (175)	AlexNet, VGG-16, DetectNet	550 panoramik radyografi	DetectNet'in tespit performans değerlendirmesi, duyarlılık, kesinlik ve F1 skorunun tamamının 1,0 olduğunu gösterdi; bu da sistemin ilgili tüm nesnelere mutlak doğrulukla tespit edebildiğini göstermektedir.
Ahn ve ark. (2021) (176)	ResNet-18, ResNet-101, SqueezeNet, Inception-ResNet-V2	1100 panoramik radyografi	ResNet-101 ve Inception-ResNet-V2'nin doğruluk, kesinlik, duyarlılık ve F1 puanlarının %90'ın üzerinde olduğu görüldü.
Ha ve ark. (2021) (177)	YOLOv3	248 panoramik radyografi	Dahili test veri seti %96,2'lik bir doğruluk oranı sergilerken, harici test veri seti orijinal görüntülerde %89,8'lik bir doğruluk oranı gösterdi.
Kim ve ark. (2022) (178)	Inception-ResNet-v2	988 panoramik radyografi	Otomatik segmentasyon kullanılarak meziodens teşhisi için ortalama doğruluk, kesinlik, F1 skoru ve eğri altında kalan alan değerleri 0,971 bulunmuştur.
Mine ve ark. (2022) (179)	AlexNet, VGG16-TL, InceptionV3-TL	220 panoramik radyografi	VGG16 modeli %82,3'lük doğruluk, %85,0'lık duyarlılık ve %79,0'lık özgüllük ile süpernümerer dişlerin tespitinde yüksek bir performans sergilemiştir.
Gömük (Submerged) Diş Tespiti			
Çalışkan ve ark. (2021) (180)	Faster R-CNN	74 panoramik radyografi	%83,72 doğruluk oranı gösteren Faster R-CNN modeli sırasıyla %83,33 kesinlik, %96,8 özgüllük, %45,45 oranında duyarlılık ile performans göstermiştir.
Ektopik Erüpsiyon Tespiti			
Zhu ve ark. (2022) (181)	U-Net	285 panoramik radyografi	Kesinlik değeri 0,845, F1 skoru 0,902, doğruluk değeri ise 0,990 olarak belirlenmiştir.
Liu ve ark. (2022) (182)	CNN	1480 panoramik radyografi	Pozitif ve negatif öngörü değerleri sırasıyla 0,86 ve 0,88 olup, özgüllük 0,90 ve duyarlılığı 0,86'dır.

Tablo 2.2. (devamı)

Dental Plak Tespiti			
You ve ark. (2020) (183)	CNN	98 intraoral fotoğraf	Geliştirilen yapay zekâ modelinin, süt dişlerindeki plağı tespit etmede klinik olarak kabul edilebilir performans seviyesine ulaştığı görülmüştür.
Fissür Örtücü ve Tespiti ve Kategorizasyonu			
Schlickenrieder ve ark. (2021) (184)	CNN ResNeXt	2352 intraoral fotoğraf	Sonuçlar, CNN'in tüm test görüntülerinin %98,7'sinde fissür örtücüleri doğru bir şekilde tespit ettiğini ve bunun da 0,996'lık bir AUC'ye karşılık geldiğini göstermiştir.
Diş Çürüğü Tespiti			
Zhou ve ark. (2022) (185)	CNN	210 panoramik radyografi	Önerilen CNN modeli sırasıyla 0,8272, 0,8538, 0,8770, 0,8652 ve 0,9005 olan doğruluk, kesinlik, duyarlılık, F1 skoru ve eğrinin altındaki alan (AUC) ile tipik CNN taban çizgisinden daha iyi performans göstermiştir.
Aşçı ve ark. (2024) (186)	U-Net	6075 panoramik radyografi	Süt, karma ve daimi dişleri içeren toplam grupta, duyarlılık, kesinlik ve F1 skorları sırasıyla 0,8269, 0,9123 ve 0,8675 olarak bulunmuştur.
Anatomik Landmark Tespiti			
Bağ ve ark. (2023) (187)	YOLOv5	981 panoramik radyografi	En iyi duyarlılık değerleri orbita, maksiller sinüs, mandibular kanal, incisura mandibula ve kondiler proçesten elde edilmiştir. En düşük duyarlılık değerleri ise mental foramen (0,92) ve artiküler eminensten (0,92) elde edilmiştir.
Taurodontizm Tespiti			
Duman ve ark. (2022) (188)	U-Net	434 panoramik radyografi	Taurodont diş segmentasyonunun duyarlılık, kesinlik ve F1 skor değerleri sırasıyla 0,8650, 0,7898 ve 0,8257 bulunmuştur.
Diş Gelişim Aşamalarının Tespiti			
Kurt ve ark. (2024) (189)	YOLOv5	1500 panoramik radyografi	Diş gelişim evresi tespit modelinin duyarlılık, kesinlik ve F1 skor değerleri sırasıyla 0,99, 0,72 ve 0,84'tür.

3. GEREÇ VE YÖNTEM

Çalışmanın etik kurul izni, Afyonkarahisar Sağlık Bilimleri Üniversitesi Klinik Araştırmalar Etik Kurulu'nun 10.10.2023 tarih ve 2023/448 sayılı kararı ile onaylandı. Çalışma, Afyonkarahisar Sağlık Bilimleri Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından 24.DUS.001 numaralı proje ile desteklendi ve çalışma Afyonkarahisar Sağlık Bilimleri Üniversitesi Pedodonti Anabilim Dalı'nda yürütüldü (EK-1).

3.1. Görüntülerin Seçilmesi

Bu tez çalışmasında, Afyonkarahisar Sağlık Bilimleri Üniversitesi Diş Hekimliği Fakültesi Pedodonti Anabilim Dalı kliniğine Ocak 2018-Nisan 2024 yılları arasında başvurmuş hastalara ait panoramik radyografiler retrospektif olarak tarandı ve üst anterior dişlerinde dens invaginatus olan hastalar çalışmaya dahil edildi (Şekil 3.1).



Şekil 3.1: Çalışmamıza dahil edilen bir hastanın 11,12,21 ve 22 numaralı dişlerinin klinik ve radyografik görünümü

Panoramik radyografiler, Windows 10 işletim sistemli, 16 GB RAM'a sahip, 1920x1080 piksel çözünürlüğünde, 15.6 inç'lik flat panel renkli ekranı (Asus B1502CBA) olan 1.3 GHz Intel Core i5 PC'de incelendi.

Çalışmaya dahil edilme kriterleri;

- Optimum şartlar altında çekilmiş, 8-18 yaş aralığındaki hastalara panoramik radyografiler
- Üst çene anterior dişlerinde tip I, tip II veya tip III dens invaginatus anomalisi tespit edilmiş hastalara ait panoramik radyografiler

Dışlama kriterleri;

- Optimum şartları karşılamayan, görüntü kalitesi yetersiz olan, teşhisi engelleyecek artefakta sahip panoramik radyografiler
- Klinik olarak doğrulanmamış, hasta dosyasında eksik bilgileri olan hastaların panoramik radyografileri
- Üst kesici dişleri eksik veya ağız içerisine sürmemiş hastalara ait panoramik radyografiler
- Üst çene anterior dişlerinde invajinasyon bölgesini içine alan çürük, restorasyon, kırık bulunan hastalara ait panoramik radyografiler

Belirtilen kriterleri sağlayan 8-18 yaş aralığındaki 355 erkek, 301 kız hastaya ait toplam 656 panoramik radyografi çalışmamıza dahil edildi.

3.2. Panoramik Radyografi Veri Setinin Elde Edilmesi

Tez çalışmamızın veri seti, Planmeca Promax 2D (Planmeca, Helsinki, Finland) cihazı ile; 62 kVp, 5 mA ve 13,8 s parametreleri ile çekilen panoramik radyografiler retrospektif olarak taranarak oluşturuldu. Panoramik radyografi veri setine dahil edilen görüntüler isim, doğum tarihi, cinsiyet gibi kişisel kimlik bilgilerini içermeyecek şekilde “jpeg” formatıyla kaydedildi.

3.3. Görüntü Değerlendirilmesi ve Etiketleme

Hazırlanan veri setleri CranioCatch (Eskişehir, Türkiye) yazılımına aktarılarak proje oluşturuldu ve etiketlemeye hazır hale getirildi. Bir görüntüdeki alanların tanımlanması ve nesnenin tanımlanan hangi bölgeye ait olduğunun belirlendiği işlem olan iki farklı etiketleme işlemi, proje içerisindeki 656 panoramik radyografiye uygulandı.


Görüntüler üzerindeki etiketlemeler, 15 yıllık deneyime sahip çocuk diş hekimi uzmanı ve 2,5 yıllık deneyime sahip bir araştırma görevlisi tarafından gerçekleştirildi. İki hekimin teşhisinin eşleşmediği panoramik radyografiler veri setinden çıkarıldı.

Etiketlemeler; elde edilen JPEG görüntüleri üzerinde web tabanlı CranioCatch (Eskişehir, Türkiye) yazılımı kullanılarak gerçekleştirildi (Şekil 3.2).




Şekil 3.2: CranioCatch yazılımında panoramik radyografi üzerinde yapılan etiketlemeler

Panoramik görüntüler üzerinde iki farklı yöntemle etiketleme yapıldı. İlk etiketleme, dens invaginatuslu dişlerdeki invajinasyon bölgesinin dış sınırlarının serbest çizim tekniğiyle belirlenerek çizilmesi (segmentasyon tekniği, poligon yöntemi) ile gerçekleştirildi ve yapılan etiketleme 'Dens in Dente' olarak kaydedildi (Şekil 3.3). İkinci etiketleme ise dens invaginatus bulunan dişlerin kronlarının aynı grafi üzerinde bounding box veya detection olarak adlandırılan yöntemle dikdörtgen şeklinde etiketlenmesiyle gerçekleştirildi ve yapılan etiketleme 'Tooth with Dens in Dente' olarak kaydedildi (Şekil 3.4).



Şekil 3.3: Dens invaginatuslu dişlerde poligon yöntemi ile invajinasyon alanının etiketlenmesi



Şekil 3.4: Dens invaginatus bulunan dişlerin kronlarının bounding box yöntemiyle etiketlenmesi

3.4. Derin Öğrenme Mimarisi ve Model Geliştirilmesi

Bu çalışmada eğitimler, Python açık kaynak programlama dili (v.3.6.1; Python Software Foundation, Wilmington, DE, ABD)'ndeki PyTorch kütüphanesi ile 2D CNN mimarileri kullanılarak gerçekleştirildi. Modellerin geliştirilmesinde, 500 eğitim adım sayısı verilerek en iyi parametrelerin bulunduğu model kaydedilerek gerçekleştirildi. Eğitimler için özellikle tıbbi görüntülerde segmentasyon için başarılı sonuçlar veren ve hızlı bir mimari olan YOLOv5 ve YOLOv8 kullanıldı. Modellerin eğitimi, Dell PowerEdge T640 Calculation Server, Dell PowerEdge T640 GPU Calculation Server, and Dell PowerEdge R540 Storage Server kullanılarak gerçekleştirildi.

3.5. Eğitim Aşaması

Sınıflandırılan ve etiketlenen görüntüler eğitim öncesinde yeniden boyutlandırıldı. Veri seti, önceden eğitilmiş bir model ile transfer öğrenimi kullanılarak eğitildi. Eğitime katılan görsellerin tekrardan test için kullanımını engellemek için veri setinin %80'i eğitim, %10'u doğrulama ve %10'u test olmak üzere üç bölüme ayrıldı (Tablo 3.1).

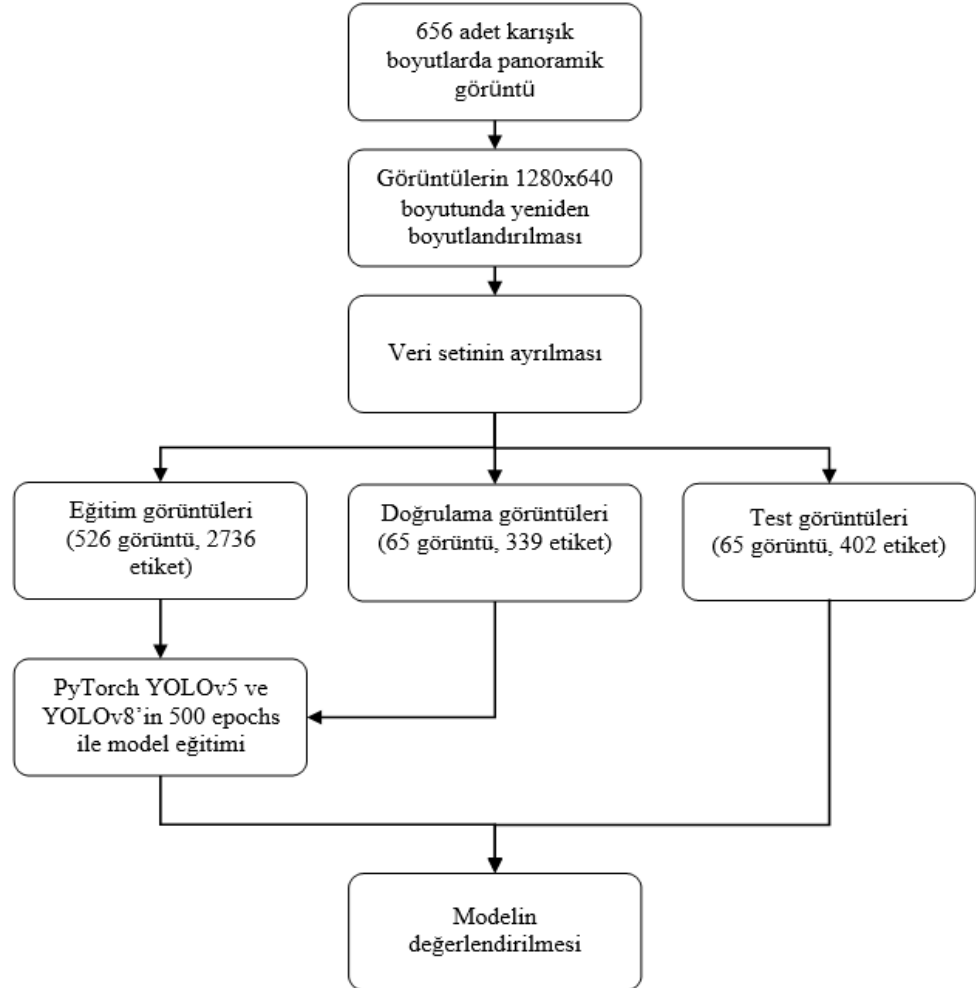
Tablo 3.1: Veri setlerinin sınıflandırılması

	Görüntü Sayısı	Etiket sayısı
Eğitim veri seti	526 görüntü	2736 etiket
Doğrulama veri seti	65 görüntü	339 etiket
Test veri seti	65 görüntü	402 etiket

-Eđitim grubu: Modelin eđitimi iin kullanılan veri setini ifade etmektedir. Görüntülerin %80'ini oluřturmaktadır.

-Dođrulama grubu: Modelin eđitiminden bađımsız olan ve bu süre boyunca modelin görmemesi gereken örnekleri ifade etmektedir. Eđitimin durdurulması veya eđitim deđiřkenlerinin revize edilmesi iin model, bu veri kümesinde sınanmaktadır. Görüntülerin %10'unu oluřturmaktadır.

-Test grubu: Eđitim ve dođrulama verilerinden faydalanılarak eđitilen modelin sınavasının yapıldıđı veri setini ifade etmektedir. Görüntülerin %10'unu oluřturmaktadır (190).



řekil 3.5: YOLOv5 ve YOLOv8 modellerinin geliřim ařamalarının akıř diyagramı

Eđitim ve dođrulama veri setleri optimal yapay zekâ algoritması ađırlık faktörlerini tahmin etmek ve üretmek için kullanıldı. Modelin başarısı test veri setiyle kontrol edildi. Dens invaginatuslu dişlerin etiketlendiđi eğitim veri seti 526 adet panoramik radyografiden oluşmakta olup bu görüntüler üzerinden 2736 adet etiketleme yapıldı. Veri setinde 65 görüntü test, 65 görüntü dođrulama görüntüleri olarak ayrıldı. YOLOv5 ve YOLOv8 modellerinin eğitimi 500 epoch (eđitim tur sayısı) yapılarak gerçekleştirildi (Şekil 3.5).

3.6. İstatiksel Analiz

Modellerin başarısını hesaplamak için tahmin edilen ve gerçek durumların karşılaştırmasını gösteren karışıklık matrisi kullanıldı (Şekil 3.6). Karışıklık matrisi, bir sınıflandırma sistemi tarafından yapılan gerçek ve tahmin edilen sınıflandırmalar hakkında bilgi içerir. Bu tür sistemlerin performansı genellikle matristeki veriler kullanılarak değerlendirilir (191).

Karışıklık matrisiyle birlikte alıcı işlem karakteristiđi (Receiver Operating Characteristic Curve-ROC) eğrileri oluşturuldu ve ROC eğrisinin altında kalan alan (Area Under Curve-AUC) hesaplandı. Böylece YOLOv5 ve YOLOv8 derin öğrenme modellerinin dens invaginatus tespitindeki performans kıyaslaması yapıldı.

3.6.1. Karışıklık Matrisi Hesaplama Prosedürü

Modelin başarısını değerlendirmek için dođru pozitif (DP), yanlış pozitif (YP) ve yanlış negatif (YN) metrikleri formülize edilerek performans ölçütleri hesaplandı. Modelin dens invaginatus tespitindeki başarısının değerlendirilmesi için aşağıdaki matrisler kullanıldı.

Modelin dens invaginatus teşhis başarısını değerlendirmek için kullanılan matrisler aşağıdaki gibidir:

Dođru pozitif (DP): Dens invaginatus bulunan dişler dođru tespit edildi.

Yanlış pozitif (YP): Dens invaginatus bulunan dişler yanlış tespit edildi.

Yanlış negatif (YN): Dens invaginatus bulunan dişler tespit edilemedi.

		SİSTEM TAHMİNİ	
		POZİTİF	NEGATİF
GERÇEK	DOĞRU	DOĞRU POZİTİF	YANLIŞ NEGATİF
	YANLIŞ	YANLIŞ POZİTİF	DOĞRU NEGATİF

Şekil 3.6: Karışıklık matrisi

3.7. Performans Değerlendirmesi

Duyarlılık (sensitivity-recall): Duyarlılık, doğru olan pozitif ve negatif değerlerin ne kadarının pozitif olarak tahmin edildiğini gösterir. Doğru pozitif örneklerin oranını hesaplamak için kullanılır. Yanlış negatifliklerin çok olduğu durumlarda duyarlılık değeri düşük çıkmaktadır. Dolayısıyla model seçiminde yüksek duyarlılık değerine sahip parametreler seçilmelidir (192).

$$Duyarlılık = \frac{DP}{DP+YN}$$

Kesinlik (precision): Tahmin edilen pozitif verilerden ne kadarının doğru tahmin edildiğini gösterir. Yani doğru tahminlerin ne kadar kesin olduğunu belirtir. Yanlış pozitifliklerin az olması modelin seçiminde önemli olacağından kesinlik değerinin yüksek olması istenmektedir (192).

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

F1 skoru: Kesinlik ve duyarlılık veri sonuçlarının harmonik ortalamasıdır. F1 skoru, sadece doğru sınıflandırılan örneklerin sayısını değil, aynı zamanda yanlış sınıflandırmaları da dikkate alarak modelin nesneyi tespit edebilme kabiliyetini hesaplar (192).

$$F1 Skoru = \frac{2x Kesinlik x Duyarlılık}{Kesinlik+Duyarlılık}$$

3.8. Alıcı İşlem Karakteristiđi (AİK-ROC)

ROC, tanısal doğruluđu incelemek için kullanılan bir grafik yöntemidir. Bu grafikte, y ekseninde duyarlılık, x ekseninde ise özgülük oranları bulunur. ROC eğrisi altındaki alanın mümkün olduğunca bire yakın bir değerde olması beklenir. Bu grafik, gerçek pozitifler ile yanlış negatifler arasındaki ilişkiyi ortaya koyar. Ayrıca, ROC eğrisi, farklı tanı yöntemlerinin karşılaştırılmasına ve uygun pozitiflik eşiđinin belirlenmesine olanak tanır. Eğri altındaki alanın (AUC) büyük olması, tahminlerin o kadar başarılı olduğunu gösterir (193).

3.9. Kesinlik- Duyarlılık Eğrisi (PR Eğrisi, Precision-Recall Curve)

PR eğrilerinin x eksenini, ROC eğrilerinin y ekseniniyle aynı değeri yani doğru pozitif oranını gösterir. PR eğrilerinde, eğrinin sağ üst köşeye yaklaşması başarı oranının arttığı anlamına gelir (194).

4. BULGULAR

Çalışmamızda, panoramik radyografi görüntüleri üzerinde derin öğrenme yöntemlerinden olan YOLOv5 ve YOLOv8 modellerinin dens invaginatus tespitindeki başarısı araştırıldı. Proje oluşturma aşamasında 656 panoramik radyografi üzerinden dens invaginatuslu dişlerin etiketlenmesi ile veri seti sınıfı oluşturuldu. Her bir model için karışıklık matrisi kullanılarak modellerin performansları değerlendirildi.

YOLOv5 modelinin, detection ve segmentasyon için dens invaginatuslu dişleri tahmin etmedeki doğru pozitif (DP), yanlış pozitif (YP) ve yanlış negatif (YN) değerleri Tablo 4.1’de verilmiştir. Eğitilen YOLOv5 modeli, test grubundaki görüntülerin 372’sini gerçek pozitif, 38’ini yanlış pozitif ve 30’unu yanlış negatif olarak değerlendirdi. Bu değerler intersection over union (IoU) threshold değeri %50 olarak seçildiği zamana göre elde edildi. YOLOv5 modeli ile 500 epoch (eğitim tur sayısı) yapılarak eğitim gerçekleştirildi ve öğrenme hızı (learning rate) değeri ise 0,01 olarak tespit edildi.


Tablo 4.1: YOLOv5 modelinin detection ve segmentasyon için DP, YP ve YN değerleri

	Doğru Pozitif (DP)	Yanlış Pozitif (YP)	Yanlış Negatif (YN)
Detection	190	24	11
Segmentasyon	182	14	19
Total	372	38	30

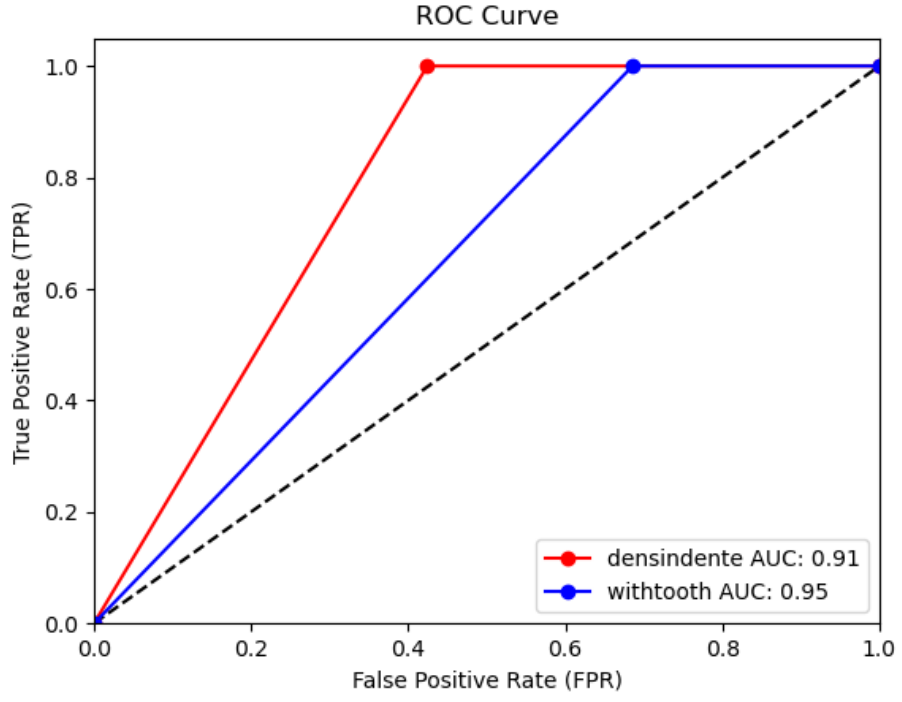
Karışıklık matrisi kullanarak hesaplanan YOLOv5 modelinin performansı Tablo 4.2’de gösterilmiştir. Duyarlılık, kesinlik ve F1 skor değerleri detection için sırasıyla 0,945, 0,887 ve 0,915 olarak, segmentasyon için 0,905, 0,928 ve 0,916 olarak tespit edildi.

Tablo 4.2: YOLOv5 modelinin detection ve segmentasyon için duyarlılık, kesinlik ve F1 skorları

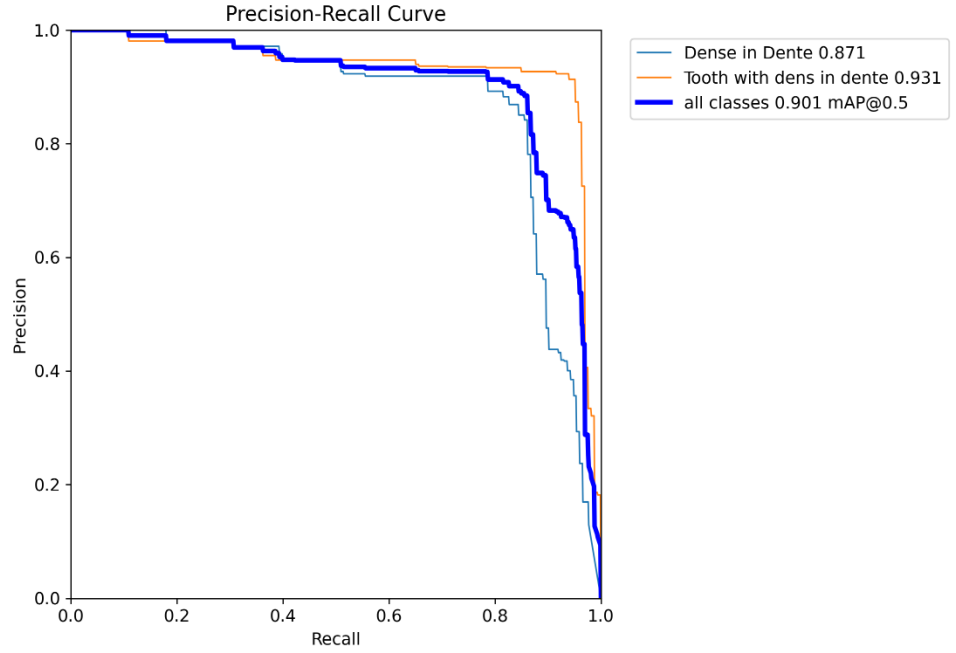
	Duyarlılık ($DP/(DP+YN)$)	Kesinlik ($DP/(DP+YP)$)	F1 skoru ($2DP/(2DP+YP+YN)$)
Detection	0,9452736318	0,8878504673	0,9156626506
Segmentasyon	0,9054726368	0,9285714286	0,9168765743




Şekil 4.1: YOLOv5 modeline ait karışıklık matrisi



Şekil 4.2: YOLOv5 modeline ait dens invaginatus tespiti için ROC eğrisi




Şekil 4.3: YOLOv5 modelinin dens invaginatus tespiti için Kesinlik-Duyarlılık (Precision-Recall) eğrisi



Şekil 4.4: YOLOv5 modelinin 12 ve 22 numaralı dişlerdeki dens invaginatus için doğru pozitif tespiti



Şekil 4.5: YOLOv5 modelinin 11 ve 21 numaralı dişler için yanlış pozitif tespiti



Şekil 4.6: YOLOv5 modelinin 11 ve 21 numaralı dişler için yanlış negatif tespiti

YOLOv8 modelinin, detection ve segmentasyon için ayrı ayrı olarak dens invaginatuslu dişleri tahmin etmedeki doğru pozitif (DP), yanlış pozitif (YP) ve yanlış negatif (YN) değerleri Tablo 4.3'te verilmiştir. Eğitilen YOLOv8 modeli, test grubundaki 526 görüntüde bulunan 2736 etiket sayısından 380'ini gerçek pozitif, 1'ini yanlış pozitif ve 22'sini yanlış negatif olarak değerlendirdi. Bu değerler intersection over union (IoU) threshold değeri %50 olarak seçildiği zamana göre elde edildi. YOLOv8 modeli ile 500 epoch (eğitim tur sayısı) yapılarak eğitim gerçekleştirildi ve öğrenme hızı (learning rate) değeri ise 0,01 olarak tespit edildi.


Tablo 4.3: YOLOv8 modelinin detection ve segmentasyon için DP, YP ve YN değerleri

	Doğru Pozitif (DP)	Yanlış Pozitif (YP)	Yanlış Negatif (YN)
Detection	191	0	10
Segmentasyon	189	1	12
Total	380	1	22

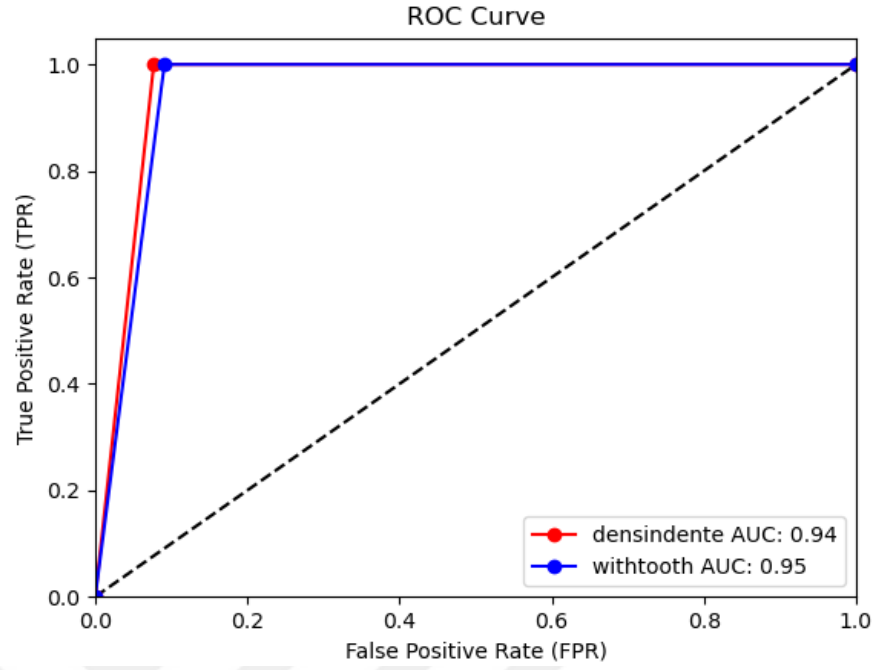
Karışıklık matrisi kullanarak hesaplanan YOLOv8 performansı Tablo 4.4'te gösterilmiştir. Duyarlılık, kesinlik ve F1 skor değerleri detection için sırasıyla 0,950, 1 ve 0,974 olarak segmentasyon için 0,940, 0,994 ve 0,966 olarak tespit edildi.

Tablo 4.4: YOLOv8 modelinin detection ve segmentasyon için duyarlılık, kesinlik ve F1 skorları


	Duyarlılık ($DP/(DP+YN)$)	Kesinlik ($DP/(DP+YP)$)	F1 skoru ($2DP/(2DP+YP+YN)$)
Detection	0,9502487562	1	0,9744897959
Segmentasyon	0,9402985075	0,9947368421	0,9667519182




Şekil 4.7: YOLOv8 modeline ait karışıklık matrisi



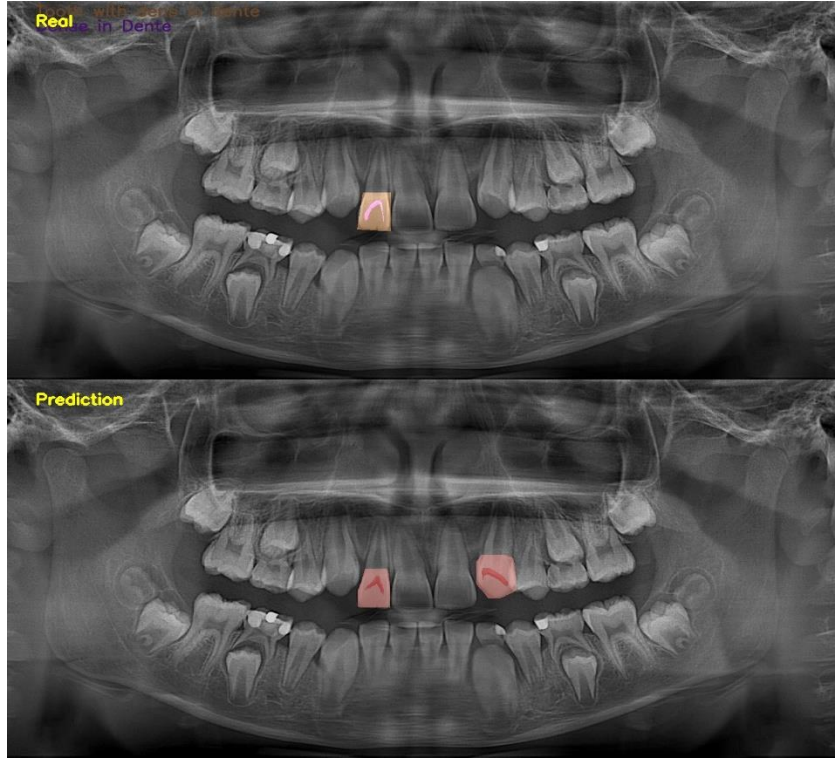
Şekil 4.8: YOLOv8 modeline ait dens invaginatus tespiti için ROC eğrisi




Şekil 4.9: YOLOv8 modelinin dens invaginatus tespiti için Kesinlik-Duyarlılık (Precision-Recall) eğrisi



Şekil 4.10: YOLOv8 modelinin 12 ve 22 numaralı dişlerdeki dens invaginatus için doğru pozitif tespiti



Şekil 4.11: YOLOv8 modelinin 23 numaralı dişteki yanlış pozitif tahmini



Şekil 4.12: YOLOv8 modelinin 11 ve 22 numaralı dişler için yanlış negatif tespiti

YOLOv5 ve YOLOv8 modellerinin dens invaginatus tespitindeki başarıları kıyaslandığında, YOLOv8 modelinin hem detection hem segmentasyon tekniğinde daha yüksek duyarlılık, kesinlik ve F1 skoru değerleri gösterdiği görülmüştür.

5. TARTIŞMA

Dental anomaliler, diş gelişimi sırasında meydana gelen deformasyonlardan kaynaklanan ve dişlerin yapısında farklılıklara yol açan değişiklikler olup çoğu zaman klinik olarak belirti göstermemeleri ve hastalar tarafından fark edilmemeleri nedeniyle genellikle radyografik ve klinik muayene sonrasında hekimler tarafından tesadüfen teşhis edilmektedirler (195). Gelişimsel dental anomalilerin biçim (şekil) bozukluklarından olan dens invaginatus, odontogenezisin morfodiferansiyasyon evresinde mine organının dental papillanın içine doğru katlanmasıyla meydana gelmektedir (196). Dens invaginatuslu dişler anormal morfolojileri sebebiyle plak retansiyonuna sebep olarak çürük, pulpa nekrozu ve periodontal enflamasyon gibi sorunlara yol açabilmektedir. Dens invaginatuslu dişlerde endodontik tedavi, invajinasyonun karmaşık anatomisi nedeniyle hekimler için çoğu zaman zorlayıcı hale gelmektedir. Bu nedenle dens invaginatus tedavisinde erken teşhis oldukça önemlidir. Erken teşhis edilen vakalarda konservatif tedavilerle mevcut invajinasyon alanında çürük gelişimi, endodontik ve periodontal problemlerin önüne geçilebilir (3).

Son yıllarda, yapay zekâ teknolojilerinin sağlık alanında kullanımı hızla artmış ve özellikle tıbbi görüntüleme tekniklerinde önemli yenilikleri ve gelişmeleri beraberinde getirmiştir (6). Bu bağlamda, dens invaginatus tespitinde yapay zekânın potansiyelini değerlendirmek önem arz etmektedir. Bu doğrultuda çalışmamızda, panoramik radyografilerde dens invaginatuslu dişlerin tespitinde derin öğrenme yöntemi kullanılarak geliştirilen yapay zekâ modelinin başarısını ve güvenilirliğini değerlendirmek amaçlanmıştır.

Dens invaginatus, en sık daimi maksiller lateral dişlerde ve çoğunlukla bilateral olarak görülmekte olup bunu maksiller santral dişler ve kanin dişleri takip eder (196). Süt dişlerinde ve mandibular dişlerde ise nadir de olsa görüldüğü rapor edilmiştir. Ayrıca süpernümerer dişlerde de dens invaginatus gözlenebilmektedir (49). Dens invaginatus, dens evaginatus, füzyon, geminasyon ve agenezi gibi dental anomalilerin dental laminanın dejenerasyonu veya hiperaktivitesi nedeniyle oluştuğu ve daha çok anterior bölgede görüldüğü öne sürülmektedir (197). Bununla birlikte, panoramik radyografilerde posterior dişlerde dens invaginatus net bir görüntü vermemektedir. Bu

sebeple çalışmamızda sadece daimi ön dişlerde görülen dens invaginatus değerlendirilmiştir (82).

Dens invaginatusun en sık görüldüğü dişler olan maksiller lateral dişlerin sekiz yaş civarında ağız içine sürmesi ve ilerleyen yaşla beraber ön dişlerde çürük, travmaya bağlı kırık, implant, protetik veya restoratif tedavi görülme ihtimalinin yüksek olması, bununla birlikte çalışmamızda özellikle çocuk ve adölesanlarda dens invaginatusun erken teşhisinin önemini vurgulamayı amaçladığımızdan çalışmamızın veri setini 8-18 yaş hastalara ait panoramik radyografiler oluşturmaktadır.

Farklı popülasyonlarda dens invaginatus prevalansı tanı kriterlerindeki farklılıklara, sınıflandırma sistemine, kullanılan radyografi türüne ve kullanılan yöntemlere bağlı olarak %0,3-10 arasında değişmektedir (44). Türk toplumunda panoramik ve periapikal radyografiler kullanarak yapılan çalışmalarda, dens invaginatus prevalansı %1,3-12 arasında değişmektedir (80–82). Yalçın ve arkadaşları ile Ceyhanlı ve arkadaşlarının çalışmalarında, dens invaginatus teşhisinde KIBT kullanılmış olup dens invaginatus prevalansı sırasıyla %5,11 ve %5,9 olarak rapor edilmiştir (94,198). Dens invaginatusun prevalansına yönelik çalışmalar, dens invaginatus sıklığının görece düşük olduğunu gösterse de klinik rutininde bu anomalinin toplumumuzda göz ardı edilemeyecek kadar sık rastlandığı ancak, çoğu zaman teşhisteki zorluklar nedeniyle geç teşhis edildiği ve bu durumun hem hastalar hem de klinisyenler için tedavi sürecini uzatarak maliyetleri artıran ve tedaviyi daha zorlayıcı hale getiren bir faktör olarak karşımıza çıktığını düşünmekteyiz.

Diş hekimliğinde radyografik değerlendirme özellikle gömülü diş, dilaserasyon, taurodontizm ve dens invaginatus gibi dental anomalilerin tespitinde önemli rol oynamaktadır (9). Dens invaginatus, vakaların birçoğunda radyografik muayenede rastlantısal olarak saptanır. Klinik olarak alışılmadık kron morfolojisi veya derin foramen caecum dens invaginatus tanısı için önemli bir gösterge olabilir ancak, kron morfolojisindeki bu değişiklikler tek başına kesin bir dens invaginatus tanısı koydurmaz (48). Etkilenen dişler aynı zamanda malformasyonun klinik belirtilerini göstermeyebileceğinden kesin tanıyı doğrulamak için radyografik incelemeye ihtiyaç duyulur. Bu sebeple radyografik değerlendirme dens invaginatusun tanısı için klinik muayene ile birlikte değerli bir araçtır (199).

Panoramik radyografi maksilla, mandibula ve bunlara ilişkin destek yapılar da dahil olmak üzere yüz yapılarının tek bir görüntüde değerlendirilmesine olanak sağlayan ve diş hekimliği rutininde sıklıkla kullanılan radyografik tekniklerden biridir (10). Panoramik radyografiler, diş ve çevre dokuların anatomisini ve morfolojisini tanımlamada, diş gelişimini belirlemede, dentomaksillofasiyal bölgedeki patolojik anomalileri tespit etmede ve yaş tahmininde yardımcı bir tanı aracı olarak kullanılabilir (200). Bununla birlikte panoramik radyografiler, ek görüntüleme tekniklerine olan ihtiyacı belirlemek için genel bir bakış sağlayabilen bir başlangıç değerlendirmesi olarak da kullanılabilir. Panoramik radyografiler, sadece iki boyutlu görüntüleme sağlasa da düşük radyasyon dozu ile daha geniş bir alanın görüntüsünün elde edilebilmesi ve kısa süre içinde görüntüye ulaşılabilmesi gibi önemli özellikleri sayesinde özellikle çocuk hastalarda avantaj sağlamaktadır (201).

Geleneksel görüntülemenin komplike endodontik durumlar hakkında tanımlayıcı bilgi sağlayamadığı vakalarda üç boyutlu radyografiler de tercih edilebilir. Bununla birlikte güncel önerilere göre KIBT kullanımının kararı, geleneksel radyografilerle karşılaştırıldığında daha yüksek radyasyon dozundan dolayı risk/fayda oranı gözetilerek verilmelidir. Ayrıca KIBT incelemesi, radyasyon miktarının yanı sıra çocuk hastalarda tarama sırasında kooperasyon eksikliği, erişilebilirlik ve yüksek maliyet gibi sınırlayıcı faktörlere sahiptir ve çocuk hastalarda radyografik değerlendirmede rutinde kullanılmamaktadır (202). Çocuk ve adölesanlar üzerinde yürüttüğümüz çalışmamızda, yapay zekânın dens invaginatus tespitindeki başarısını değerlendirmek amacıyla klinik rutininde sıklıkla kullanılan ve dens invaginatusun ön teşhisi için yeterli görüntülemeyi sağlayan panoramik radyografiler kullanıldı.

Dens invaginatusun tanımlanmasında farklı sınıflandırmalar mevcut olup Oehlers tarafından önerilen ve iki boyutlu radyografik değerlendirmeye dayalı olan dens invaginatus sınıflaması, isimlendirilmedeki ve uygulamadaki kolaylığı nedeniyle en yaygın kullanılan sınıflama olarak görünmektedir (1). Oehlers sınıflamasına göre üç tip invajinasyon çeşidi bulunmaktadır. Tip I dens invaginatus, mine-sement sınırını aşmayan, dişin kron kısmı ile sınırlı, mineyle kaplı invajinasyon şeklinde izlenir. Tip II dens invaginatus, mine-sement sınırını geçerek köke ilerleyen, mineyle kaplı, kör bir kese olarak biten invajinasyonlar şeklinde izlenir. Pulpa odasıyla bağlantısı olabilmekte

ancak, periodontal ligament ile ilişkisi bulunmamaktadır. Tip III dens invaginatus, mine-sement sınırını geçip apikal bölgeye kadar uzanan, diş kökünün yan yüzeyinden ya da apikal bölgeden periodontal ligament boşluğuna açılan invajinasyonlar şeklinde görülmektedir (61). Yapılan prevalans çalışmalarda genel kanı, dens invaginatus tipleri arasında en sık tip I dens invaginatusun görüldüğü şekildedir (1,79). Tez çalışmamıza dahil ettiğimiz panoramik radyografilerde de en çok tip I dens invaginatusa sahip hastaya (n=604) rastlanılmış olup, bunu sırasıyla tip II (n=48) ve tip III (n=4) dens invaginatus izlemiştir. Çalışmamıza dahil ettiğimiz panoramik radyografilerde tip II ve tip III dens invaginatusun sayıca daha az olmasının gruplar arası homojeniteyi sağlayamamasından dolayı çalışmamızda dens invaginatus tiplerine göre ayırım yapılmadan tüm dişler genel bir dens invaginatus kimliği altında etiketlenmiştir.

Dens invaginatuslu dişlerin tedavisinde çeşitli yaklaşımlar mevcuttur ve bunlar büyük ölçüde dens invaginatusun tipine ve pulpanın sağlık durumuna göre değişiklik gösterir. Dens invaginatuslu dişlerde invajinasyon, pulpal dokulardan yalnızca ince bir mine ve dentin tabakasıyla ayrılan ölü bir alan yaratır. Bu alan, mikroorganizmaların ve diğer potansiyel iritanların girişine olanak tanıyarak diş çürüğü ve dolayısıyla pulpa nekrozu gelişimi için bir yatkınlık sağlar (44). Ayrıca dens invaginatus apse oluşumu, kist oluşumu, dişlerin yer değiştirmesi ve internal kök rezorpsiyonu gibi problemlere de neden olabilmektedir. İnvajinasyonun koruyucu olarak kapatılması, doldurulması veya pulpa etkilenmişse vital pulpa tedavisi, cerrahi olmayan kök kanal tedavisi, apeksifikasyon veya rejeneratif endodontik prosedürler, periradiküler cerrahi, kasıtlı replantasyon veya çekim dens invaginatuslu dişlerin tedavi seçenekleri arasındadır (105).

Dens invaginatuslu dişlerin kök kanal tedavisinde, kanallardaki düzensiz şekillenmelerden dolayı kanal tedavisi sırasında çeşitli problemlerle karşılaşılabilir. Dens invaginatus lezyonlarının karmaşık anatomisi nedeniyle, endodontik kemomekanik debridman ve kanal dolumu son derece zor olabilmektedir. Özellikle dens invaginatuslu açık apeksli dişlerde apikal daralım olmaması kanal dolumunu zorlaştırmaktadır. Ayrıca endodontik tedavide flare-up, perforasyon ve kök kanalında kanal aleti kırılması gibi bazı risk faktörleri mevcuttur. Bununla birlikte özellikle çocuk hastalar çoğu zaman endodontik tedaviyi tolere etmekte zorlanmaktadır.

Şiddetli invajinasyon ve anatomik düzensizliklerden dolayı kök kanal sisteminin tüm alanlarına erişim sağlanamadığı endodontik tedavide başarısızlık durumunda dişin çekimi de yapılabilmektedir. Bu doğrultuda dens invaginatusun özellikle erken dönemde teşhis edilmesi, koruyucu tedavilerle çürük lezyonlarının önlenmesi ile endodontik tedavi gereksiniminin azaltılması oldukça önemlidir (44).

Yapay zekâ, insan davranışını taklit eden ve problem çözmeye, nesne tanıma, karar verme gibi karmaşık görevleri yerine getiren bilgisayar biliminin yeni bir dalı olmakla beraber sağlık, savunma, mühendislik gibi birçok alanda kullanılmaya ve geliştirilmeye devam etmekte ve günlük hayatı etkilemektedir (5,203). Son yıllarda sağlık alanında yapay zekâ ve özellikle derin öğrenme algoritmaları, hastalık riskinin tahmin edilmesi, hastalıkların teşhis edilmesi ve prognozunun değerlendirilmesi, anomali ve patolojilerin tespit edilmesi, anatomik yapıların incelenmesi gibi konularda önemli ilerlemeler kaydetmiş olup gelişmeye devam etmektedir (5). Yapay zekânın özellikle görüntü tanıma ve analizindeki üstün yetenekleri, tıbbi tanı süreçlerinde önemli faydalar sağlamıştır. Yapay zekâ, büyük görüntü veri kümelerinden klinik verileri hızlı ve doğru bir şekilde çıkarma yeteneği nedeniyle diş hekimliğinde de büyük umut vaat etmektedir. Hekimler için karar destek mekanizması olması ve radyografileri yorumlamak için gereken süreyi azaltması sayesinde klinik hizmetlerin verimliliğini önemli ölçüde artıracığı düşünülmektedir (166).

Son yıllarda, yapay zekâ ve derin öğrenme metotları kullanılarak diş hekimliğinin neredeyse tüm alanlarında çeşitli çalışmalar yapılmaktadır. Bu uygulamalar, hekimin iş yükünü azaltmakta, tanı süreçlerini hızlandırmakta ve potansiyel insan hatasını minimize etmektedir. Çocuk diş hekimliğinde yapay zekâ uygulamaları; süt ve daimi dişlerin tespiti, çürük tespiti, plak tespiti, yaş tahmini, dental anomali tespiti, anatomik alanların tespiti gibi konulara odaklanmıştır (7). Yapay zekânın çocuk diş hekimliğine entegrasyonu, teşhis ve tedavi kalitesini artırma ve tedavi sonuçlarını iyileştirme potansiyeline sahiptir. Ancak, çocuk diş hekimliği alanında daha geniş ve niteliksel veri kümesiyle daha fazla araştırmaya ihtiyaç vardır. Klinik ortamlarda yapay zekânın uzun vadeli etkinliğini ve güvenilirliğini değerlendirmek için farklı derin öğrenme mimarilerinin test edilmesi gerekmektedir (204).

Derin öğrenme ağları, görüntü analizi için genellikle etiketli görüntüler kullanmaktadır. Buradaki en büyük zorluklardan biri doğru bir etiket oluşturmaktır. Derin öğrenme yöntemleri kullanılarak geliştirilen yapay zekâ modelleri için gözlemcinin sağladığı eğitim verileri ne kadar doğru ve kesin olursa sonuçlar da o kadar başarılı olacaktır. Ancak, hekimler arasındaki deneyim ve beceri farklılıkları tanınabilir doğruluğu etkileyebilmektedir. Bu nedenle yapay zekâ modellerinde başarılı sonuçlara ulaşmak için eğitimlerde kullanılan verilerin deneyimli hekimler tarafından sağlanması ve referans standartlar oluşturularak etiketleme yapılması gerekmektedir (205). Bununla beraber çalışmada birden fazla gözlemcinin olması, bireysel sınırlamaların ve hataların azaltılması açısından önemlidir (206). Bu tez çalışmasında derin öğrenme modelinin eğitimi için kullanılan veriler 15 yıllık deneyime sahip bir uzman çocuk diş hekimi ve 2,5 yıllık deneyime sahip bir araştırma görevlisi tarafından değerlendirilmiş ve etiketlemeler fikir birliğine dayanarak yapılmıştır. Gelecek çalışmalarda, gözlemci sayısının artırılması ve farklı bölümlerden farklı deneyime sahip diş hekimlerinin seçilmesiyle başarı kıyaslaması yapılabilir.

Yapay zekâ çalışmalarında radyografik görüntülerin etiketlenmesi için CranioCatch, Colabeler, Labelimg veya LabelMe gibi birçok yazılım mevcuttur. Bu tür yazılımlarda çalışma için seçilen görüntüler programa yüklendikten sonra dikdörtgen kutu şeklinde veya poligon etiketleme yöntemi ile etiketlenecek alan, manuel olarak işaretlenir ve nesnelere kimlik ataması yapılır (207). Çalışmamızda yapay zekânın dens invaginatus tespitindeki başarısını değerlendirmek için radyografik görüntüler üzerinde dişlerin etiketlemesinde CranioCatch (Eskişehir, Türkiye) yazılımı kullanıldı ve dens invaginatuslu dişlerde invajinasyon alanı poligon yöntemi kullanılarak etiketlendi. Ayrıca dens invaginatuslu dişlerin kronları da kutu (bounding box) şeklinde ikinci bir etiket olarak aynı grafide işaretlendi.

Literatürde derin öğrenme algoritmaları kullanılarak farklı dental anomalilerin tespiti ve sınıflandırması amacıyla yapılan birçok çalışma mevcuttur. Çocuk diş hekimliğinde dental anomalileri değerlendiren yapay zekâ çalışmalarının özellikle süpernümerer diş tespiti üzerine yoğunlaştığı görülmektedir. Farklı algoritma yöntemlerinin değerlendirildiği literatürdeki çalışmaların bulguları genel olarak incelendiğinde; çoğunun yüksek doğruluk gösterdiği öne sürülmüştür. Özellikle derin

öğrenme yöntemlerinden DetectNet, VGG-16, ResNet-101 ve Inception-ResNet-V2'nin süpernümerer diş tespitinde oldukça yüksek duyarlılık, kesinlik ve F1 skoru gösterdiği bildirilmiştir (175,176,178,179).

Sürme anomalilerinden ektojik erüpsiyon ile ilgili çocuk hastaların panoramik radyografileri üzerinde yapılan çalışmalarda, kullanılan evrişimli sinir ağı (CNN) tabanlı yapay zekâ modellerinin, diş hekimlerine kıyasla ektojik erüpsiyonu tespit etmede daha yüksek doğruluk ve tutarlılık gösterdiği öne sürülmüştür (181,182).

Duman ve arkadaşlarının yaptıkları çalışmada, panoramik radyografilerde taurodont dişlerin tespiti için derin öğrenmeye dayalı CNN tabanlı U-Net yapay zekâ modeli kullanılmıştır. Modelin performansı, duyarlılık, kesinlik ve F1 skoru gibi çeşitli metriklerle değerlendirilmiş ve uzman hekim düzeyine yakın sonuçlar elde edilmiştir (188).

Okazaki ve arkadaşlarının, derin öğrenme modellerinden AlexNet'in panoramik radyografilerde süpernümerer dişler ve odontomalari tespit etmedeki potansiyelini değerlendirmeyi amaçlayan çalışmalarında, AlexNet modelinin performans ölçütleri doğruluk, kesinlik, duyarlılık ve F1 skoru için sırasıyla %70, %70,8, %70 ve %69,7 olarak bulunmuştur (208).

Yapılan başka bir çalışmada, derin öğrenme yöntemlerinin bir türü olan R-CNN modelleri ile diş ve çevresindeki bölgelerde bulunan kalsifikasyon, çürük ve anomaliler dahil olmak üzere 17 dental anomali tespit edilmeye çalışılmıştır. Çalışma, CNN'lerin genel olarak yüksek doğrulukta tanımlamayı başardığını göstermiştir. Süpernümerer dişler %97,4, eksternal kök rezorpsiyonu %99,3, gömülü dişler %92,3, periapikal radyolusensi %89,5, rezidüel kök %97,2 ve mandibular kanalla çakışan dişler %93,4 oranında otomatik olarak tanımlanmıştır (209).

Literatür incelendiğinde, diş hekimliği alanındaki yapay zekâ çalışmalarında çeşitli derin öğrenme modellerinin kullanıldığı görülmektedir. Derin öğrenme, özellikle karmaşık verilerin değerlendirilmesi ve çeşitli görevlerde insan seviyesinde performans elde edilmesi konusunda oldukça etkilidir. Bu alanda, görüntü tanıma ve nesne algılama gibi görevler için birçok derin öğrenme modeli geliştirilmiştir. Bu modellerden biri olan

YOLO (You Only Look Once), gerçek zamanlı nesne segmentasyonu ve tespiti için kullanılan en popüler CNN tabanlı modeller arasında yer almaktadır.

YOLO algoritması, nesnelere tek seferde algılayarak hızlı ve yüksek doğrulukta nesne algılama ve segmentasyonunu mümkün kılmaktadır (210). Bir görüntüden veya görüntü dizilerinden gerçek zamanlı olarak birden fazla nesneyi aynı anda tespit edebilmektedir. Diğer CNN'ler de nesne tespiti için kullanılabilirken YOLO nesne tanıma modellerinin en son sürümüdür (156). YOLO'nun tasarım mimarisi, çok daha basit bir yapıya sahip olmasına rağmen çok hızlı ve doğru nesne algılama ve sınıflandırma sonuçları elde edebilmektedir. YOLO'nun diğer nesne tespit yöntemlerine kıyasla oldukça hızlı olması, nesnelere sınıflandırılması ve lokalizasyonu konusunda yüksek doğruluk göstermesi, tek bir ağ geçişiyle tüm görüntüyü işleyerek gerçek zamanlı uygulamalarda kullanılabilmesi gibi avantajları mevcuttur (210,211).

YOLO algoritması, 2015'ten bu yana ilk sürüm olan YOLOv1'den günümüze kadar geliştirilmiştir. Tüm YOLO sürümleri arasında, nesne tespiti için en popüler modeller olan YOLOv5 ve YOLOv8, Ultralytics tarafından sırasıyla 2020 ve 2023 yıllarında geliştirilmiştir (212). YOLOv5'i önceki versiyonlardan ayıran en önemli fark, DarkNet yerine PyTorch kütüphanesi kullanması ve yazılım dilinin Python olmasıdır. Bu sayede daha hızlı eğitim yapabilmeyi mümkün kılmakta olup önemli avantajlar sağlamaktadır. YOLOv8 modeli ise YOLO'nun en güncel versiyonlarından biridir ve nesne tespiti, görüntü sınıflandırma ve segmentasyon görevleri için kullanılabilir. YOLOv8, daha gelişmiş özellikler ve optimizasyonlar ekleyerek performansı artırmak için tasarlanmış YOLOv5'in bir uzantısıdır (213). YOLO mimarisi medikal görüntüleme hızı, doğruluğu ve verimliliği ile ön plana çıkmakta ve yaygın olarak tercih edilmektedir. Çalışmamızda da, dens invaginatus tespitinde tek aşamalı derin öğrenme modelleri olan YOLOv5 ve YOLOv8 kullanılmıştır.

Literatürde diş hekimliği alanında YOLO algoritması kullanılarak yapılan birçok çalışma bulunmaktadır. Ha ve arkadaşları, YOLOv3 tabanlı yapay zekâ modelini kullanarak meziodens tespiti için panoramik radyografiler üzerinde yaptıkları çalışmada, görüntülerde modelin doğruluğu dahili veri setinde %96,2, harici veri setinde %89,8 olmuştur. Ayrıca, radyografik görüntülerin iyileştirilmesi amacıyla kullanılan

CLAHE (Contrast Limited Adaptive Histogram Equalization) yönteminin, modelin performansı üzerindeki etkisi de incelenmiş ve iyileştirilen görüntüler, her iki test setinde de orijinal görüntülerden daha düşük doğruluk sağlamıştır (177).

Kaya ve arkadaşlarının yapmış oldukları bir çalışmada, 5-13 yaş aralığındaki 4518 çocuk hastaya ait panoramik radyografide daimi diş germinin otomatik tespiti için YOLOv4 modeli kullanılmış ve modelin kesinlik değeri %94,16, F1 skoru 0,90 olarak bulunmuştur (168).

Panoramik radyografilerde gözlemlenen anatomik yapıların tespitinde yapay zekâ destekli modellerin başarısını ve güvenilirliğini değerlendirmeyi amaçlayan bir çalışmada, çocuk hastaların panoramik radyografisinde dokuz önemli anatomik yapıyı otomatik olarak tespit etmek için YOLOv5 modelleri geliştirmiştir. Etiketlenen anatomik bölgeler için en iyi duyarlılık değerleri orbita (1), maksiller sinüs (0,99), mandibular kanal (0,99), incisura mandibula (0,99) ve kondiler proçesten (0,99) elde edilmiştir. En düşük duyarlılık değerleri ise mental foramen (0,92) ve artiküler eminesten (0,92) elde edilmiştir. Düzenli ve standart etiketleme, nispeten daha büyük alanlar ve YOLOv5 algoritmasının başarısı bu başarılı sonuçların elde edilmesine katkıda bulunmuştur (187).

Karma dentisyon dönemindeki çocuk hastalara ait panoramik radyografilerde diş tespiti ve segmentasyonu için YOLOv5 derin öğrenme modeli kullanılan bir çalışmada, diş tespiti için duyarlılık, kesinlik, F1 skoru ve ortalama kesinlik (mAP) değerleri sırasıyla 0,99, 0,99, 0,99 ve 0,98; diş segmentasyonu için duyarlılık, kesinlik, F1 skoru ve mAP@0.5 değerleri sırasıyla 0,98, 0,98, 0,98 ve 0,98 olarak bulunmuştur. Sonuç olarak YOLOv5 tabanlı modellerin, karma dentisyona sahip çocuk hastaların panoramik radyografileri kullanılarak süt ve daimi dişlerin doğru segmentasyonunu sağlama ve tespit etme potansiyeline sahip olduğu görülmüştür (169).

Çocuk hastaların panoramik radyografilerinde diş gelişim aşamalarının değerlendirildiği bir çalışmada, derin öğrenme tabanlı bir yapay zekâ algoritması olan YOLOv5, dişlerin kalsifikasyon durumlarını otomatik olarak tespit etmek amacıyla eğitilmiştir. Modelin diş gelişim aşamalarını tespit etmedeki başarısı oldukça yüksek bulunmuştur. Modelin duyarlılık oranı %99, kesinlik oranı %72 ve F1 skoru %84 olarak

hesaplanmıştır. Çalışmanın sonuçlarına göre, çocuklardaki diş gelişim aşamalarını otomatik olarak tespit etmek için kullanılan YOLOv5 modelinin performansı, diş gelişimi ile kronolojik yaş arasındaki ilişkinin doğru bir şekilde değerlendirilmesine olanak tanımaktadır (189).

Erişilebilir literatürde dens invaginatusun otomatik tespitinde YOLOv5'i kullanan bir çalışmaya rastlanmamıştır. Bu konuda bir ilk olan çalışmamızda, detection yöntemi ile etiketlemeler sonucu YOLOv5 modelinin kesinlik, duyarlılık ve F1 skoru sırasıyla 0,945, 0,887 ve 0,915 iken segmentasyon yöntemi için bu değerler 0,905, 0,928, 0,916 olarak bulunmuş ve modelin dens invaginatus tespitinde potansiyel bir başarıya sahip olduğu gözlemlenmiştir. YOLOv5 algoritması kullanarak gerçekleştirdiğimiz çalışmamızın bulguları ile kıyaslandığında, anatomik landmark tespiti ve diş germi tespiti gibi daha büyük ve belirgin alanların ve yapıların etiketlendiği çalışmalarda modelin performansının daha yüksek olduğu gözlemlenmiştir. Dolayısıyla geniş alanların daha kolay ve doğru bir şekilde tanımlanabilmesinin, yapay zekâ modelinin bu tür görevlerdeki başarısını artıran temel faktörlerden biri olabileceğini düşünmekteyiz.

Mandibulada bulunan radyolusent lezyonların otomatik tespiti ve segmentasyonu için YOLOv8 modeli kullanılan bir çalışmada, 200 panoramik radyografideki 226 radyolusent lezyon değerlendirilmiş ve modelin başarı oranı kesinlik, duyarlılık ve ortalama kesinlik (mAP) gibi performans ölçütleri kullanılarak değerlendirilmiştir. Sonuçlar, modelin hem tespit hem de segmentasyonda yüksek değerlendirme metrikleriyle dikkate değer bir performans sergilediğini doğrulamıştır (214).

Bitewing radyografilerde interproksimal, oklüzal ve sekonder çürüklerin otomatik tespitini ve sınıflandırılmasını gerçekleştirmeyi amaçlayan bir çalışmada, YOLOv8 derin öğrenme algoritmasıyla eğitilen model, 860 radyografiden oluşan bir veri seti üzerinde test edilmiştir. Test sonuçlarına göre, modelin kesinlik %97,7, duyarlılık oranı %93,2 ve F1 skoru %95,4 olarak elde edilmiştir (215).

Tez çalışmamızda kullanılan bir diğer model olan YOLOv8'in dens invaginatus tespitinde detection ve segmentasyon yöntemleri ile etiketlemeler yapılmış ve

modellerin başarısının değerlendirilmesinde kesinlik, duyarlılık ve F1 skoru parametreleri kullanılmıştır. Detection yöntemi ile etiketlemeler sonucu YOLOv8 modelinin kesinlik, duyarlılık ve F1 skoru sırasıyla, 0,950, 1 ve 0,974 iken segmentasyon yöntemi için bu değerler 0,940, 0,994, 0,966 olarak bulunmuştur. Çalışmamızda kullanmış olduğumuz her iki yapay zekâ modelinde detection için elde edilen değerler, segmentasyona göre daha başarılı bulunmuştur. Anomaliyi içeren daha geniş alanın çizim ile eğitilmesinde model; farklı threshold değerleri içeren yapıdaki aykırı alanı daha rahat tespit edebilirken, bir anomaliyi sadece işaret etmek ve tam sınırlarını tespit etmek için daha fazla sayıda veri gerekir. Ancak bizim çalışmamızda bu segmentasyon değerleri bile yüksek başarı sunmuştur.

Panoramik radyografilerde yapay zekâ modelleri ile dens invaginatusun tespitini amaçlayan bir tez çalışmasında, 10 yaşından büyük 400 hastanın panoramik radyografisi çalışmaya dahil edilmiş ve tek aşamalı YOLOv8 ve YOLOv9 modelleri ile iki aşamalı Faster R-CNN modeli kullanılmıştır. Panoramik radyografilerde dens invaginatuslu lateral dişlerin singulum alanı işaretlenerek etiketleme yapılmıştır. Sonuçlar duyarlılık, kesinlik, F1 skoru ve ortalama tespit süresini içeren performans metriklerine göre değerlendirilmiştir. YOLOv8 modelinin duyarlılık, kesinlik ve F1 skoru değerleri eşit ve 0,904 olarak bulunmuştur. Elde edilen bulgulara göre test edilen tüm modellerin %90'ın üzerinde başarı sağladığı görülmüştür (216). Çalışmanın bulguları, mevcut çalışmamızdaki YOLOv8 modeli ile duyarlılık, kesinlik ve F1 skoru açısından kıyaslandığında çalışmamızda daha başarılı sonuçların elde edildiği görülmektedir. Bu farklılığın, çalışmamıza dahil edilen veri seti sayısının daha fazla olması, kullanılan etiketleme yazılımlarının farklı olması ve etiketleme yöntemindeki farklılıktan kaynaklandığını düşünmekteyiz. Çalışmamızda, dens invaginatuslu dişlerdeki invajinasyon bölgesinin dış sınırları serbest çizim tekniğiyle belirlenerek poligon tarzı etiketleme yapılmış bununla birlikte dens invaginatus bulunan dişlerin kronları da ikinci bir etiket olarak aynı grafide işaretlenerek etiketleme yapılmıştır. Özellikle etiketleme yöntemindeki farklılığın elde edilen sonuçlarda farklılığa neden olmuş olabileceğini düşünmekteyiz.

Yapılan bir çalışmada, 600 panoramik radyografiden oluşan çok sınıflı bir veri seti kullanılarak YOLOv5, YOLOv7 ve YOLOv8 modellerinin anatomik yapı ve dental

tedavilerin tespiti ve segmentasyonundaki performansları değerlendirilmiş ve YOLOv5s'in en düşük tespit ve segmentasyon değeri gösterdiği ancak, nesne tespiti için kullanılabilir düzeyde olduğu görülmüştür. Bununla birlikte, YOLOv7m ile en iyi tespit performansı sonuçlarını elde edilirken, YOLOv8m'in segmentasyon açısından YOLOv7m'den daha iyi performans gösterdiği görülmüştür (217). Tez çalışmamızda da benzer şekilde YOLOv8 hem segmentasyon hem tespit açısından YOLOv5 modelinden daha başarılı sonuçlar göstermiştir.

Yapay zekânın sunduğu yüksek hassasiyet, hızlı analiz ve sürekli öğrenme yetenekleri, dens invaginatus tespitinde önemli avantajlar sunmaktadır. Dens invaginatus gibi spesifik bir dental anomalinin tespitinde derin öğrenme modellerinin kullanılması, yapay zekânın özellikle karmaşık görüntüleri analiz etme kapasitesi nedeniyle umut vaat edicidir ve tanı sürecinde karar destek mekanizması olma potansiyeline sahiptir. Bununla birlikte, yapay zekâ modellerinin nesne tespitinde performansını etkileyen çeşitli faktörler bulunmaktadır. Bu teknolojilerin etkili bir şekilde kullanılması, yapay zekâ algoritmalarının doğru verilerle yeterince eğitilmesini gerektirir. Kullanılan veri setinin kalitesi ve çeşitliliği, modelin genel performansında kritik bir rol oynamaktadır. Eğer veri seti, yeterince çeşitli değilse veya düşük kalitede görüntüler içeriyorsa, modelin başarısız olma riski vardır. Ancak, dens invaginatus gibi nispeten nadir görülen anomaliler için yeterli veri sağlanması zor olabilmektedir. Veri eksikliği, yapay zekâ algoritmalarının eğitimini ve doğruluğunu olumsuz etkileyebilir. Çalışmamıza 8-18 yaş aralığındaki 656 hastanın panoramik radyografisi dahil edilmiştir. Gelecekteki çalışmalarda dahil etme kriterleri genişletilip veri sayısının artırılması ve klinik uygulamalar için daha kullanışlı yapay zekâ algoritmaları elde etmek amacıyla daha büyük bir popülasyon üzerinde çalışılabilir.

Çalışmamızın bulgularını etkileyen önemli faktörlerden biri dens invaginatuslu dişlerin etiketlenmesinde yaşanan zorluktur. Özellikle rotasyonlu ya da aşırı çapraşık olan dişlerde invajinasyon alanının radyografide net bir şekilde izlenmemesi ve bu durumun doğru bir etiket oluşturmayı engellemesinin neden olduğu düşünülmektedir. İnvajinasyon alanını içine alan kırık, restorasyon, çürük bulunması da doğru bir etiket oluşturmayı zorlaştırmaktadır. Bununla birlikte bazı görüntülerde, anomali sınırlarını belirlemek zor olabilmektedir. Bu durum, diş yapısıyla arasındaki ince farkların görüntülerde net olarak görülmemesiyle birlikte görsel karışıklığa yol açarak etiketleme

sırasında doğru sınırların çizilmesini zorlaştırabilir ve algoritmanın eğitimi için gerekli olan net veriyi sağlayamayabilir. Çalışmamızda iki farklı etiketleme yöntemi kullanılarak bu hatanın en aza indirgenmesi hedeflenmiştir.

Çalışmamızda, yapay zekâ modellerinin dens invaginatus bulunan dişleri tespit etmedeki tahmin modelleri incelendiğinde, özellikle dişlerin singulum bölgelerinin ve rotasyonlu dişlerde mine kenarlarının dens invaginatus olarak yanlış pozitif sınıflandırıldığı gözlemlenmiştir. Bu durum, modellerin karmaşık diş anatomisini ayırt etmede zorlandığını ve bazı anatomik yapıların anomali olarak algılandığını göstermektedir. Yanlış negatif sonuçların ise düşük çözünürlüklü panoramik radyografilerde lezyon detaylarının yeterince belirgin olmaması ve dişlerin anatomik yapılarındaki farklılıkların, algoritmanın anomaliyi doğru şekilde analiz etmesini zorlaştırması nedeniyle ortaya çıktığı görülmüştür. Bu bulgular, model performansının iyileştirilmesi ve özellikle daha gelişmiş özellik çıkarımı ve segmentasyon tekniklerine ihtiyaç duyulduğunu ortaya koymaktadır.

Çalışmamızda veri setini oluşturan tüm görüntüler tek bir kurumdan alınan aynı panoramik cihazda ve aynı parametreler ile çekilen görüntülerden oluşmaktadır. Farklı kurumlardan, farklı cihazlarla ve farklı çekim parametreleri ile elde edilecek görüntülerle yapılacak olan çalışmalar ile yapay zekâ modelinin performansı artırılarak daha etkin yapay zekâ modelleri elde edilebilir. Bununla birlikte dens invaginatus tespitinde hem iki boyutlu hem de üç boyutlu çeşitli görüntüleme tekniklerinden elde edilen verilerin bir arada kullanılması modelin doğruluk oranını artırabilir.

Çalışmamızın limitasyonlarından biri, dens invaginatus tiplerine göre ayırım yapılmadan tüm dişlerin genel bir dens invaginatus kimliği altında etiketlenmiş olmasıdır. Yapay zekâ çalışmalarında kullanılan veri setlerinin homojen dağılımının kullanılan algoritmanın performansını arttırdığı bilinmektedir (218). Ancak çalışmamıza dahil ettiğimiz panoramik radyografilerdeki tip II ve tip III dens invaginatuslu diş sayısının daha az olması nedeniyle ayırım yapılmadan etiketleme yapılmıştır. Farklı tiplerdeki dens invaginatuslu dişlerin klinik ve radyografik görünüşleri farklılık gösterdiğinden tip bazında bir ayırım yapılması, lezyonların daha detaylı bir şekilde analiz edilmesini ve sonuçların daha spesifik hale getirilmesini sağlayabilir. İlerleyen çalışmalar için, her bir tipin ayrı olarak ele alınması ve analiz edilmesi, daha spesifik ve

güvenilir sonuçlar elde edilmesine olanak sağlayacaktır.

Dens invaginatus tespitinde yapay zekâ kullanımı, bu sistemlerin teşhis sürecinde değerli bir destek mekanizması olarak rol oynayabileceğini göstermektedir. Ancak, bu teknolojilerin etkinliklerinin ve güvenilirliklerinin artırılması için daha fazla sayıda ve kapsamlı araştırmaya ihtiyaç duyulmaktadır. Özellikle yapay zekâ modellerinin sürekli olarak güncellenmesi, optimize edilmesi ve klinik uygulamalara entegrasyon süreçlerinin iyileştirilmesi, bu alanda kaydedilecek ilerlemeler açısından kritik adımlar teşkil etmektedir. İlerleyen dönemlerde, yapay zekânın diş hekimliği uygulamalarında daha yaygın ve etkili bir şekilde kullanılmaya başlanmasıyla birlikte dens invaginatus gibi dental anomalilerin erken teşhis ve tedavisi daha erişilebilir ve hızlı hale gelebilir. Yapay zekâ destekli bir gelecekte, diş hekimliği pratiğinde tanı ve tedavi süreçlerinde kayda değer iyileşmelerin yaşanması muhtemeldir. Bu gelişmeler hem klinik doğruluğun artmasına hem de hasta sonuçlarının iyileşmesine önemli katkılar sağlayacaktır.

6. SONUÇ VE ÖNERİLER

1. Çocuk ve adölesan hastalara ait panoramik radyografiler üzerinde derin öğrenme yöntemiyle geliştirilmiş yapay zekâ modellerinin dens invaginatus tespitindeki başarısının incelendiği bu çalışmada, detection yöntemi ile etiketlemeler sonucu YOLOv5 modelinin kesinlik, duyarlılık ve F1 skoru sırasıyla 0,945, 0,887 ve 0,915 iken segmentasyon yöntemi için bu değerler 0,905, 0,928, 0,916 olarak bulunmuştur.

2. Detection yöntemi ile etiketlemeler sonucu YOLOv8 modelinin kesinlik, duyarlılık ve F1 skoru sırasıyla 0,950, 1 ve 0,974 iken segmentasyon yöntemi için bu değerler 0,940, 0,994, 0,966 olarak bulunmuştur.

3. YOLOv8 modelinin, YOLOv5 modeline kıyasla daha yüksek başarı gösterdiği bulunmuştur. Hem YOLOv5 hem de YOLOv8 modellerinde segmentasyon yöntemiyle etiketlemede elde edilen sonuçlar, detection yöntemi ile elde edilen sonuçlardan daha başarılı bulunmuştur.

4. Farklı cihazlardan elde edilen, farklı çekim parametreleri ile elde edilmiş görüntülerin kullanılması klinik kullanım açısından daha geçerli yapay zekâ modellerinin elde edilmesini sağlayabilir. Yapay zekâ modellerinin başarısının daha iyi tespit edilebilmesi için ilerideki çalışmalarda farklı uzmanlık seviyelerine sahip diş hekimleri ile başarılarının karşılaştırıldığı çalışmalar yapılabilir.

5. Çalışmamızın dens invaginatus tiplerinin ayrımının yapılmaması, sadece iki boyutlu radyografiler üzerinde yürütülmüş olması gibi limitasyonları olmasına karşın; sadece çocuk ve adölesan hastalara ait radyografiler üzerinde yürütülmüş olması, iki farklı etiketleme yönteminin karşılaştırılması ve derin öğrenme yöntemleri ile dens invaginatus tespiti konusunda literatürdeki çalışmaların oldukça az olması nedeniyle özgün değerinin yüksek olduğunu düşünmekteyiz.

6. Sonuç olarak bu çalışma, yapay zekâ teknolojilerinin çocuk ve adölesan hastalarda dens invaginatus tespiti için etkili bir araç olabileceğini göstermekte ve gelecekte yapılacak araştırmalar için önemli bir temel oluşturmaktadır. Geliştirilen algoritmaların klinik pratikte başarılı bir şekilde uygulanması, teşhis sürecinde hekimler için yardımcı bir araç ve karar destek mekanizması olma potansiyelini ortaya koymaktadır.

7. KAYNAKLAR

1. Alani A, Bishop K. Dens invaginatus. Part 1: Classification, prevalence and aetiology. *Int Endod J* 2008;41(12):1123–36.
2. Hook H, Power G. Dens invaginatus: a review of its aetiology, diagnosis and clinical management. *Dent Update* 2024;51(6):428–32.
3. Clarke P, Longridge N, Gartshore L. A multidisciplinary management of a type III dens invaginatus in a maxillary permanent canine. *Eur Arch Paediatr Dent* 2016;17(2):131–6.
4. Neville B, Damm D, Allen C, Bouquot J. *Oral and Maxillofacial Pathology* (4th ed.), Elsevier Health Sciences, Philadelphia, 2015.
5. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac Radiol* 2020;49(1):20190107.
6. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol* 2017;2(4):230–43.
7. Vishwanathaiah S, Fageeh HN, Khanagar SB, Maganur PC. Artificial intelligence its uses and application in pediatric dentistry: A review. *Biomedicines* 2023;11(3):788.
8. Thesleff I, Sharpe P. Signalling networks regulating dental development. *Mech Dev* 1997;67(2):111–23.
9. White SC, Pharoah MJ. Dental anomalies. In: *Oral radiology: principles and interpretation* (8th ed.), Mosby, 2018.
10. Bilge NH, Yeşiltepe S, Törenek Ağırman K, Çağlayan F, Bilge OM. Investigation of prevalence of dental anomalies by using digital panoramic radiographs. *Folia Morphol (Warsz)* 2018;77(2):323–8.
11. Saberi EA, Ebrahimipour S. Evaluation of developmental dental anomalies in digital panoramic radiographs in Southeast Iranian Population. *J Int Soc Prev Community Dent* 2016;6(4):291–5.
12. Brook AH. Multilevel complex interactions between genetic, epigenetic and environmental factors in the aetiology of anomalies of dental development. *Arch Oral Biol* 2009;54:S3–17.
13. Shapira Y, Kuftinec MM. Tooth transpositions-a review of the literature and treatment considerations. *Angle Orthod* 1989;59(4):271–6.
14. Amasyalı M, Alakuş Sabuncuoğlu F, Akgün ÖM, Erşahan Eroğlu Ş. Dişlerde görülen gelişim anomalileri: genel bir bakış. *Türkiye Klinikleri* 2018;1–4.
15. Nunn JH, Carter NE, Gillgrass TJ, Hobson RS, Jepson NJ, Meechan JG, et al. The interdisciplinary management of hypodontia: background and role of paediatric dentistry. *Br Dent J* 2003;194(5):245–51.
16. Solares R, Romero MI. Supernumerary premolars: a literature review. *Pediatr Dent* 2004;26(5):450–8.

17. Al-Ani AH, Antoun JS, Thomson WM, Merriman TR, Farella M. Hypodontia: an update on its etiology, classification, and clinical management. *Biomed Res Int* 2017;2017:1–9.
18. Brook AH. A unifying aetiological explanation for anomalies of human tooth number and size. *Arch Oral Biol* 1984;29(5):373–8.
19. Oflaz Ü, Akgün ÖM. Dişlerde görülen boyut anomalileri. *Türkiye Klinikleri* 2018;55–9.
20. Kyriazidou A, Haider D, Mason C, Parekh S, Bloch-Zupan A. Case report: Macrodont mandibular second premolars, a hereditary dental anomaly. *Eur Arch Paediatr Dent* 2013;14(6):411–6.
21. Laverty DP, Thomas MBM. The restorative management of microdontia. *Br Dent J* 2016;221(4):160–6.
22. Welbury R, Duggal M, Hosey M. Abnormality of tooth structure. In: *Pediatr. Dent (5th ed.)*, Oxford University Press, 2005: p.316.
23. Crawford PJ, Aldred M, Bloch-Zupan A. Amelogenesis imperfecta. *Orphanet J Rare Dis* 2007;2(1):17.
24. Seow W. Developmental defects of enamel and dentine: challenges for basic science research and clinical management. *Aust Dent J* 2014;59(1):143–54.
25. Gadhia K, McDonald S, Arkutu N, Malik K. Amelogenesis imperfecta: an introduction. *Br Dent J* 2012;212(8):377–9.
26. Shields ED, Bixler D, El-Kafrawy AM. A proposed classification for heritable human dentine defects with a description of a new entity. *Arch Oral Biol* 1973;18(4):543–53.
27. Bailleul-Forestier I, Berdal A, Vinckier F, de Ravel T, Fryns JP, Verloes A. The genetic basis of inherited anomalies of the teeth. Part 2: Syndromes with significant dental involvement. *Eur J Med Genet* 2008;51(5):383–408.
28. American Academy of Pediatric Dentistry. Guideline on dental management of heritable dental developmental anomalies. *Pediatr Dent* 2013;35(5):E179–84.
29. Hart PS, Hart TC. Disorders of human dentin. *Cells tissues organs* 2007;186(1):70–7.
30. Kırzioğlu Z, Seven N, Yılmaz Y. Shell dişler: olgu sunumu. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi* 1998;8(2):67–70.
31. Witkop CJ. Hereditary defects of dentin. *Dent Clin North Am* 1975;19(1):25–45.
32. Carroll MKO, Duncan WK. Dentin dysplasia type I. Radiologic and genetic perspectives in a six-generation family. *Oral Surg. Oral Med. Oral Radiol* 1994;78(3):375–81.
33. Guzman R, Elliott MA, Rossie KM. Odontodysplasia in a pediatric patient: literature review and case report. *Pediatr Dent* 1990;12(1):45–8.
34. Hamdan MA, Sawair FA, Rajab LD, Hamdan AM, Al-Omari IK. Regional odontodysplasia: a review of the literature and report of a case. *Int J Paediatr Dent* 2004;14(5):363–70.

35. Pinkham J, Casamassimo P, Mc Tighe D, Fields HJ, Nowak A. Pediatric dentistry- infancy through adolescence (4th ed.), Mosby, 2005.
36. Tirali RE. Füzyon: bir literatür güncellemesi. ADO Klinik Bilimler Dergisi 2010;4(2):590–4.
37. Altun C, Güven G, Başak F, Akbulut E, Altuğ HA. Süt dişlerinde füzyon ve geminasyon: beş olgu nedeniyle. EADS 2005;32(3):223–7.
38. Slootweg PJ. Dental Pathology: A Practical Introduction (2nd ed.) Springer, Berlin, Heidelberg, 2013: 27–29.
39. Kaur R, Walia PS, Rohilla AK, Choudhary S. Review of dilaceration of maxillary central incisor: A multidisciplinary challenge. Int J Clin Pediatr Dent 2016;9(1):90–8.
40. Jafarzadeh H, Azarpazhooh A, Mayhall JT. Taurodontism: a review of the condition and endodontic treatment challenges. Int Endod J 2008;41(5):375–88.
41. Kulkarni G, Rajeev K, Ambalavanan P, Kidiyoor K. Successful endodontic management of hypo, meso and hypertaurodontism: two case reports. Contemp Clin Dent 2012;3(6):253.
42. Levitan ME, Himel VT. Dens evaginatus: literature review, pathophysiology, and comprehensive treatment regimen. J Endod 2006;32(1):1–9.
43. Stecker S, DiAngelis AJ. Dens evaginatus: a diagnostic and treatment challenge. JADA 2002;133(2):190–3.
44. Hülsmann M. Dens invaginatus: aetiology, classification, prevalence, diagnosis, and treatment considerations. Int Endod J 1997;30(2):79–90.
45. Schulze C. Developmental abnormalities of the teeth and jaws. In: Thoma's Oral Pathology. 1970:96–183.
46. Gonçalves A, Gonçalves M, Oliveira DP, Gonçalves N. Dens invaginatus type III: report of a case and 10-year radiographic follow-up. Int Endod J. 2002;35(10):873–9.
47. Koparal Eden E, Koca H, Şen BH. Dens invaginatus in a primary molar: report of case. ASDC J Dent Child 2002;69(1):49-53.
48. Zhu J, Wang X, Fang Y, Von den Hoff JW, Meng L. An update on the diagnosis and treatment of dens invaginatus. Aust Dent J 2017;62(3):261–75.
49. Hamasha AA, Alomari QD. Prevalence of dens invaginatus in Jordanian adults. Int Endod J 2004;37(5):307–10.
50. Kronfeld R. Dens in Dente. J Dent Res 1934;14(1):49–66.
51. Rushton MA. Invaginated teeth (dens in dente): contents of the invagination. Oral Surg Oral Med Oral Pathol 1958;11(12):1378–87.
52. Gustafson G, Sundberg S. Dens in dente. Br Dent J. 1950;88.
53. Fischer C. Zur Frage des Dens in dente (In German). Deutsche Zahn-, Mund- und Kieferheilkunde. 1936;3:621–34.
54. Ohazama A, Courtney JM, Sharpe PT. Opg, Rank, and Rankl in tooth development: co-ordination of odontogenesis and osteogenesis. J Dent Res

2004;83(3):241–4.

55. Kettunen P, Laurikkala J, Itäranta P, Vainio S, Itoh N, Thesleff I. Associations of FGF-3 And FGF-10 with signaling networks regulating tooth morphogenesis. *Dev Dyn* 2000;219:322–32.
56. Dassule HR, Lewis P, Bei M, Maas R, McMahon AP. Sonic hedgehog regulates growth and morphogenesis of the tooth. *Development* 2000;127(22):4775–85.
57. Casamassimo PS, Nowak AJ, Ettinger RL, Schlenker DJ. An unusual triad: microdontia, taurodontia, and dens invaginatus. *Oral Surg. Oral Med. Oral Radiol* 1978;45(1):107–12.
58. Ireland EJ, Black JP, Scures CC. Short roots, taurodontia and multiple dens invaginatus. *J Pedod* 1987;11(2):164–75.
59. Hosey MT, Bedi R. Multiple dens invaginatus in two brothers. *Dent Traumatol* 1996;27;12(1):44–7.
60. Grahnen H. Dens invaginatus. I. A clinical, roentgenological and genetical study of permanent upper lateral incisors. *Odontol Revy* 1959;10:115–37.
61. Oehlers FA. Dens invaginatus (dilated composite odontome). *Oral Surg. Oral Med. Oral Radiol* 1957;10(11):1204–18.
62. Hibbert S. A previously unreported association between Nance-Horan syndrome and spontaneous dental abscesses. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod* 2005;99(2):207–11.
63. Pokala P, Acs G. A constellation of dental anomalies in a chromosomal deletion syndrome (7q32): case report. *Pediatr Dent* 1994;16(4):306–9.
64. Hallet G. The incidence, nature, and clinical significance of palatal invaginations in the maxillary incisor teeth. *Proc R Soc Med* 1953;46:491–9.
65. Vincent-Townend J. Dens invaginatus. *J Dent* 1974;2(6):234–8.
66. Ulmansky M, Hermel J. Double dens in dente in a single tooth. *Oral Surg. Oral Med. Oral Radiol* 1964;17(1):92–7.
67. Schulze C, Brand E. Dens invaginatus (dens in dente). *ZWR* 1972;81(14):653–60.
68. Gallacher A, Ali R, Bhakta S. Dens invaginatus: Diagnosis and management strategies. *Br Dent J* 2016;221(7):383–7.
69. Oehlers FA. The radicular variety of dens invaginatus. *Oral Surg. Oral Med. Oral Radiol* 1958;11(11):1251–60.
70. Mupparapu M, Singer S. A rare presentation of dens invaginatus in a mandibular lateral incisor occurring concurrently with bilateral maxillary dens invaginatus : Case report and review of literature. *Aust Dent J* 2004;49(2):90–3.
71. Neves FS, Dos Anjos Pontual A, Campos PSF, Frazão MAG, De Almeida SM, De Moraes Ramos-Perez FM. Radicular dens invaginatus in a mandibular premolar: Cone-beam computed tomography findings of a rare anomaly. *Oral Radiol* 2013;29(1):70–3.
72. Lee KW, Lee EC, Poon KY. Palato-gingival grooves in maxillary incisors. *A*

- possible predisposing factor to localised periodontal disease. *Br Dent J* 1968;124(1):14–8.
73. Goon WWY, Carpenter WM, Brace NM, Ahlfeld RJ. Complex facial radicular groove in a maxillary lateral incisor. *J Endod* 1991;17(5):244–8.
 74. Simon JHS, Glick DH, Frank AL. Predictable endodontic and periodontic failures as a result of radicular anomalies. *Oral Surg. Oral Med. Oral Radiol* 1971;31(6):823–6.
 75. Gannepalli A, Ayinampudi BK, Podduturi SR. Radicular dens invaginatus associated with radicular cyst in maxillary third molar-Rare case report. *J Pierre Fauchard Acad* 2014;28(4):133–6.
 76. Ruprecht A, Batniji S, Sastry KA, el-Neweihi E. The incidence of dental invagination. *J Pedod* 1986;10(3):265–72.
 77. Hovland EJ, Block RM. Nonrecognition and subsequent endodontic treatment of dens invaginatus. *J Endod* 1977;3(9):360–2.
 78. Tagger M. Nonsurgical endodontic therapy of tooth invagination. *Oral Surg Oral Med Oral Pathol* 1977;43(1):124–9.
 79. Ridell K, Mejäre I, Matsson L. Dens invaginatus: a retrospective study of prophylactic invagination treatment. *Int J Paediatr Dent* 2001;11(2):92–7.
 80. Çakıcı F, Çelikoglu M, Arslan H, Topçuoğlu HS, Erdoğan AŞ. Assessment of the prevalence and characteristics of dens invaginatus in a sample of Turkish Anatolian population. *Med Oral Patol Oral Cir Bucal* 2010;15(6):855-8.
 81. Gündüz K, Çelenk P, Canger EM, Zengin Z, Sümer P. A retrospective study of the prevalence and characteristics of dens invaginatus in a sample of the Turkish population. *Med Oral Patol Oral Cir Bucal* 2013;18(1).
 82. Kırzioğlu Z, Ceyhan D. The prevalence of anterior teeth with dens invaginatus in the western mediterranean region of Turkey. *Int Endod J* 2009;42(8):727–34.
 83. Bäckman B, Wahlin YB. Variations in number and morphology of permanent teeth in 7-year-old Swedish children. *Int J Paediatr Dent* 2001;11(1):11–7.
 84. Ezoddini AF, Sheikhha MH, Ahmadi H. Prevalence of dental developmental anomalies: a radiographic study. *Community Dent Health* 2007;24(3):140–4.
 85. Çolak H, Tan E, Aylıkçı BU, Uzgur R, Turkal M, Hamidi MM. Radiographic Study of the Prevalence of Dens Invaginatus in a Sample Set of Turkish Dental Patients. *J Clin Imaging Sci* 2012;2:34.
 86. Patil S, Doni B. Prevalence of Dens Invaginatus in North Indian Population. *OMPJ* 2013;4(1).
 87. Ceyhanlı KT, Büyük SK, Şekerci AE, Karataş M, Çelikoğlu M, Benkli YA. Investigation of dens invaginatus in a Turkish subpopulation using conebeam computed tomography. *Oral Health Dent Manag* 2015;14(2):81–4.
 88. Capar ID, Ertas H, Arslan H, Ertas ET. A retrospective comparative study of cone-beam computed tomography versus rendered panoramic images in identifying the presence, types, and characteristics of dens invaginatus in a Turkish population. *J Endod* 2015;41(4):473–8.

89. Różyło TK, Różyło-Kalinowska I, Piskórz M. Cone-beam computed tomography for assessment of dens invaginatus in the Polish population. *Oral Radiol* 2018;34(2):136–42.
90. Mabrouk R, Berrezouga L, Frih N. The accuracy of CBCT in the detection of dens invaginatus in a Tunisian population. *Int J Dent* 2021;2021:1–5.
91. Alkadi M, Almohareb R, Mansour S, Mehanny M, Alsadhan R. Assessment of dens invaginatus and its characteristics in maxillary anterior teeth using cone-beam computed tomography. *Sci Rep* 2021;11(1):19727.
92. Chen L, Li Y, Wang H. Investigation of dens invaginatus in a Chinese subpopulation using Cone-beam computed tomography. *Oral Dis* 2021;27(7):1755–60.
93. Hegde V, Mujawar A, Shanmugasundaram S, Sidhu P, Narasimhan S, Setzer FC, et al. Prevalence of dens invaginatus and its association with periapical lesions in a Western Indian population-a study using cone-beam computed tomography. *Clin Oral Investig* 2022;26(9):5875–83.
94. Yalçın TY, Kayhan KB, Yılmaz A, Göksel S, Özcan İ, Yiğit DH. Prevalence, classification and dental treatment requirements of dens invaginatus by cone-beam computed tomography. *PeerJ* 2022;10.
95. Varun K, Arora M, Pubreja L, Juneja R, Middha M. Prevalence of dens invaginatus and palatogingival groove in North India: A cone-beam computed tomography-based study. *J Conserv Dent* 2022;25(3):306–10.
96. Altınbulak H, Ergül N. Multiple dens invaginatus. *Oral Surg Oral Med Oral Radiol* 1993;76(5):620–2.
97. Sousa SMG, Bramante CM. Dens invaginatus: treatment choices. *Dent Traumatol* 2007;14(4):152–8.
98. Rotstein I, Stabholz A, Heling I, Friedman S. Clinical considerations in the treatment of dens invaginatus. *Dent Traumatol* 1987;3(5):249–54.
99. De Smit A, Demaut L. Nonsurgical endodontic treatment of invaginated teeth. *J Endod* 1982;8(11):506–11.
100. Bishop K, Alani A. Dens invaginatus. Part 2: Clinical, radiographic features and management options. *Int Endod J* 2008;41(12):1137–54.
101. Achabi N, Chhoul H, Ramdi HR. Clinical guideline for diagnosis and treatment of dens invaginatus. *Integr J Med Sci* 2021;8:1-4
102. Shapiro L. Dens in dente. *Oral Surg Oral Med Oral Pathol* 1970;30(6):782.
103. Chaturvedula BB, Muthukrishnan A, Bhuvaraghan A, Sandler J, Thiruvengkatachari B. Dens invaginatus: a review and orthodontic implications. *Br Dent J* 2021;230(6):345-350
104. Seow W. Diagnosis and management of unusual dental abscesses in children. *Aust Dent J* 2003;48(3):156–68.
105. Siqueira JF, Rôças IN, Hernández SR, Brisson-Suárez K, Baasch AC, Pérez AR, et al. Dens invaginatus: clinical implications and antimicrobial endodontic treatment considerations. *J Endod* 2022;48(2):161–70.

106. Gold NS, Mary P, Sangavi T, Venkatesh A, Prakash V, Student P. Dens invaginatus clinical diagnosis and management: A review. *EJMCM* 2020;7(5):1275-80.
107. Ranganathan J, Rangarajan Sundaresan MK, Ramasamy S. Management of Oehler's type III dens invaginatus using cone beam computed tomography. *Case Rep Dent* 2016;2016:1–6.
108. Abella F, Morales K, Garrido I, Pascual J, Duran-Sindreu F, Roig M. Endodontic applications of cone beam computed tomography: case series and literature review. *G Ital Endod.* 2015;29(2):38–50.
109. Piattelli A, Tris P. Dens invaginatus: a histological study of undemineralized material. *Dent Traumatol* 1993;9(5):191–5.
110. Omnell KA, Swanbeck G, Lindahl B. Dens Invaginatus II. A microradiographical, histological and micro x-ray diffraction study. *Acta Odontol Scand* 1960;18(3):303–30.
111. Beynon AD. Developing dens invaginatus (dens in dente). A quantitative microradiographic study and a reconsideration of the histogenesis of this condition. *Br Dent J* 1982;153(7):255–60.
112. Morfis AS. Chemical analysis of a dens invaginatus by SEM microanalyses. *J Clin Pediatr Dent* 1993;17(2):79–82.
113. Gaitonde P, Bishop K. Apexification with mineral trioxide aggregate: an overview of the material and technique. *Eur J Prosthodont Restor Dent* 2007;15(1):41–5.
114. Schmitz MS, Montagner F, Flores CB, Morari VHC, Quesada GAT, Gomes BPPA. Management of dens invaginatus type I and open apex: report of three cases. *J Endod* 2010;36(6):1079–85.
115. Girsch W, McClammy T. Microscopic removal of dens invaginatus. *J Endod* 2002;28(4):336–9.
116. Jung M. Endodontic treatment of dens invaginatus type III with three root canals and open apical foramen. *Int Endod J* 2004;37(3):205–13.
117. Ali Elfa MA, Dawood MET. Using artificial intelligence for enhancing human creativity. *JADM* 2023;2(2):106-20.
118. Bhatt P, Muduli A. Artificial intelligence in learning and development: a systematic literature review. *EJTD* 2023;47(7/8):677–94.
119. Genesereth MR, Nilsson NJ. *Logical Foundations of Artificial Intelligence.* Morgan Kaufmann Publishers, 1987.
120. Nabiyev V. *Yapay Zeka: Problemler-Yöntemler-Algoritmalar (5th ed.)* Seçkin Yayıncılık, 2013.
121. Atalay M, Çelik E. Büyük veri analizinde yapay zeka ve makine öğrenmesi uygulamaları. *MAKU SOBED* 2017;9(22):155–72.
122. Turing AM. Computing machinery and intelligence. *Mind* 1950;59:433–60.
123. Kutlusoy Z. Felsefe Açısından Yapay Zeka. In: *Yapay Zeka ve Gelecek.* Doğu

- Kitabevi, İstanbul, 2019: 25–43.
124. Artificial Intelligence: Definition & Risks-Infineon Technologies [Internet]. Available from: <https://www.infineon.com/cms/en/discoveries/definition-artificial-intelligence> Access date: 02.01.2024
 125. Russell S, Norvig P. Artificial Intelligence: A Modern Approach (4th ed.), Pearson, 2021.
 126. Toosi A, Bottino AG, Saboury B, Siegel E, Rahmim A. A Brief History of AI: How to Prevent Another Winter (A Critical Review). *PET Clin* 2021;16(4):449–69.
 127. Arslan K. Eğitimde Yapay zeka ve uygulamaları. *Batı Anadolu Eğitim Bilimleri Dergisi* 2020;11(1):71–88.
 128. Haenlein M, Kaplan A. A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *Calif Manage Rev* 2019;61(4):5–14.
 129. Simeone O. A Brief Introduction to Machine Learning for Engineers. Now Publishers, 2018.
 130. Khanagar SB, Al-ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry - A systematic review. *J Dent Sci* 2021;16(1):508-22.
 131. Ghosh M, Thirugnanam A. Introduction to Artificial Intelligence. 2021,23-44.
 132. Wang X, Lin X, Dang X. Supervised learning in spiking neural networks: A review of algorithms and evaluations. *Neural Networks* 2020;125:258-80.
 133. Öztemel E. Yapay Sinir Ağları (1th ed.) Papatya Yayıncılık, İstanbul, 2003.
 134. Neves AC, González I, Leander J, Karoumi R. A New Approach to Damage Detection in Bridges Using Machine Learning. In: International Conference on Experimental Vibration Analysis for Civil Engineering Structures. 2018:73–84.
 135. Yılmaz A, Kaya U. Derin Öğrenme (4th ed.) Kodlab Yayın Dağıtım, 2022.
 136. Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâya genel bir bakış. *Takvim-i Vekayi* 2018;6(2):25–36.
 137. Krenker A, Bester J, Kos A. Introduction to the Artificial Neural Networks. In: Artificial Neural Networks-Methodological Advances and Biomedical Applications. InTech, Croatia, 2011:3-18.
 138. Deng L, Yu D. Deep Learning: Methods and Applications. *Foundations and Trends in Signal Processing*. 2014;7(3–4):197–387.
 139. Schulz H, Behnke S. Deep Learning (In German). *KI- Künstliche Intelligenz*. 2012;26(4):357–63.
 140. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015;521(7553):436–44.
 141. Abdel-Hamid O, Mohamed A rahman, Jiang H, Deng L, Penn G, Yu D. Convolutional neural networks for speech eecognition. *IEEE/ACM* 2014;22(10):1533–45.
 142. Lecun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *IEEE* 1998;86(11):2278–324.

143. Albawi S, Mohammed TA, Al-Zawi S. Understanding of a convolutional neural network. In: International Conference on Engineering and Technology (ICET). IEEE; 2017:1–6.
144. Şeker A, Diri B, Balık HH. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. GMBD 2017;3(3):47–64.
145. İnik Ö, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. GBAD 2017;6(3):85–104.
146. Doğan F, Türkoğlu İ. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. DÜMF Mühendislik Dergisi 2019;10(2):409–45.
147. Hochreiter S, Schmidhuber J. Long short-term memory. Neural Comput 1997;9(8):1735–80.
148. Kılınç HÇ. Uzun-kısa süreli bellek ağlarının nehir akım tahmininde farklı optimizasyonlarla karşılaştırılması ve tekil spektrum analizinin etkisi. EJOSAT 2021;23:248–53.
149. Hinton G, Deng L, Yu D, Dahl G, Mohamed A, Jaitly N, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups. IEEE Signal Process Mag 2012;29(6):82–97.
150. Shetty D, C.A H, Varma MJ, Navi S, Ahmed MR. Diving deep into deep learning: history, evolution, types and applications. IJITEE 2020;9(3):2835–46.
151. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. Commun ACM 2017;60(6):84–90.
152. Akın E, Şahin ME. Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. EMO Bilimsel Dergi 2024;14(1):27–38.
153. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, et al. Going deeper with convolutions. IEEE CVPR 2014:1–9.
154. Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, et al. ImageNet large scale visual recognition challenge. Int J Comput Vis. 2014;115(3):211–52.
155. Fang Y, Guo X, Chen K, Zhou Z, Ye Q. Accurate and automated detection of surface knots on sawn timbers using YOLO-V5 model. Bioresources 2021;16(3):5390–406.
156. Redmon J, Divvala S, Girshick R, Farhadi A. You Only Look Once: Unified, Real-Time Object Detection. In: IEEE CVPR 2016:779–88.
157. Nepal U, Eslamiat H. Comparing YOLOv3, YOLOv4 and YOLOv5 for autonomous landing spot detection in faulty UAVs. Sensors 2022;22(2):464.
158. Ganatra N, Patel A. A comprehensive study of deep learning architectures, applications and tools. IJCSE 2018;6(12):701–5.
159. Erickson BJ, Korfiatis P, Akkus Z, Kline T, Philbrick K. Toolkits and libraries for deep learning. J Digit Imaging 2017;30(4):400–5.
160. Akdoğan C, Özdemir H. Yapay zekanın diş hekimliği pratiğine kazanımları. Türk Diş Hekimliği Araştırma Dergisi 2024;2(3):278–87.
161. Ghods K, Azizi A, Jafari A, Ghods K. Application of Artificial Intelligence in

- Clinical Dentistry, a Comprehensive Review of Literature. *J Dent (Shiraz)* 2023;24(4):356–71.
162. Ahmed N, Abbasi MS, Zuberi F, Qamar W, Halim MS Bin, Maqsood A, et al. Artificial intelligence techniques: analysis, application, and outcome in dentistry- a systematic review. *Biomed Res Int* 2021;2021: 9751564.
 163. Agrawal P, Nikhade P. Artificial intelligence in dentistry: past, present, and future. *Cureus* 2022;14(7):e27405.
 164. Mohammad-Rahimi H, Rokhshad R, Bencharit S, Krois J, Schwendicke F. Deep learning: A primer for dentists and dental researchers. *J Dent* 2023;130:104430.
 165. Ghaffari M, Zhu Y, Shrestha A. A review of advancements of artificial intelligence in dentistry. *Dent Rev* 2024;4(2):100081.
 166. Büyük C. Diş Hekimliğinde Yapay Zeka. In: *Yapay Zeka: Büyük Veri Teknolojileri ve Yaklaşımları*. Nobel Akademik Yayıncılık, 2020:233–56.
 167. Kılıc MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, et al. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofac Radiol* 2021;50(6):20200172.
 168. Kaya E, Gunec HG, Aydın KC, Urkmez ES, Duranay R, Ates HF. A deep learning approach to permanent tooth germ detection on pediatric panoramic radiographs. *Imaging Sci Dent* 2022;52(3):275.
 169. Beser B, Reis T, Berber MN, Topaloglu E, Gungor E, Kılıc MC, et al. YOLO-V5 based deep learning approach for tooth detection and segmentation on pediatric panoramic radiographs in mixed dentition. *BMC Med Imaging* 2024;24(1):172.
 170. Bunyarit SS, Jayaraman J, Naidu MK, Yuen Ying RP, Nambiar P, Asif MK. Dental age estimation of Malaysian Chinese children and adolescents: Chaillet and Demirjian's method revisited using artificial multilayer perceptron neural network. *Aust. J. Forensic Sci* 2020;52(6):681–98.
 171. Zaborowicz M, Zaborowicz K, Biedziak B, Garbowski T. Deep learning neural modelling as a precise method in the assessment of the chronological age of children and adolescents using tooth and bone parameters. *Sensors* 2022;22(2):637.
 172. Lee YH, Won JH, Auh QS, Noh YK. Age group prediction with panoramic radiomorphometric parameters using machine learning algorithms. *Sci Rep* 2022;12(1):11703.
 173. Baydoğan MP, Baybars SC, Tuncer SA. Age detection by deep learning from dental panoramic radiographs. *AITA* 2022;2(2):51–8.
 174. Aljameel SS, Althumairy L, Albassam B, Alsheikh G, Albluwi L, Althukair R, et al. Predictive artificial intelligence model for detecting dental age using panoramic radiograph images. *Big Data Cogn. Comput* 2023;7(1):8.
 175. Kuwada C, Arijji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, et al. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol* 2020;130(4):464–9.


176. Ahn Y, Hwang JJ, Jung YH, Jeong T, Shin J. Automated mesiodens classification system using deep learning on panoramic radiographs of children. *Diagnostics* 2021;11(8):1477.
177. Ha EG, Jeon KJ, Kim YH, Kim JY, Han SS. Automatic detection of mesiodens on panoramic radiographs using artificial intelligence. *Sci Rep* 2021;11(1):23061.
178. Kim J, Hwang JJ, Jeong T, Cho BH, Shin J. Deep learning-based identification of mesiodens using automatic maxillary anterior region estimation in panoramic radiography of children. *Dentomaxillofac Radiol* 2022;51(7): 20210528.
179. Mine Y, Iwamoto Y, Okazaki S, Nakamura K, Takeda S, Peng T, et al. Detecting the presence of supernumerary teeth during the early mixed dentition stage using deep learning algorithms: A pilot study. *Int J Paediatr Dent* 2022;32(5):678–85.
180. Çalışkan S, Tuloglu N, Celik O, Ozdemir C, Kizilaslan S, Bayrak S. A pilot study of a deep learning approach to submerged primary tooth classification and detection. *Int J Comput Dent* 2021;24(1):1–9.
181. Zhu H, Yu H, Zhang F, Cao Z, Wu F, Zhu F. Automatic segmentation and detection of ectopic eruption of first permanent molars on panoramic radiographs based on nnU-Net. *Int J Paediatr Dent* 2022;32(6):785–92.
182. Liu J, Liu Y, Li S, Ying S, Zheng L, Zhao Z. Artificial intelligence-aided detection of ectopic eruption of maxillary first molars based on panoramic radiographs. *J Dent* 2022;125:104239.
183. You W, Hao A, Li S, Wang Y, Xia B. Deep learning-based dental plaque detection on primary teeth: a comparison with clinical assessments. *BMC Oral Health* 2020;20(1):141.
184. Schlickerieder A, Meyer O, Schönewolf J, Engels P, Hickel R, Gruhn V, et al. Automatized detection and categorization of fissure sealants from intraoral digital photographs using artificial intelligence. *Diagnostics* 2021;11(9):1608.
185. Zhou X, Yu G, Yin Q, Liu Y, Zhang Z, Sun J. Context aware convolutional neural network for children caries diagnosis on dental panoramic radiographs. *Comput Math Methods Med* 2022;2022:1–8.
186. Asci E, Kilic M, Celik Ö, Cantekin K, Bircan HB, Bayrakdar İŞ, et al. A deep learning approach to automatic tooth caries segmentation in panoramic radiographs of children in primary dentition, mixed dentition, and permanent dentition. *Children* 2024;11(6):690.
187. Bağ İ, Bilgir E, Bayrakdar İŞ, Baydar O, Atak FM, Çelik Ö, et al. An artificial intelligence study: automatic description of anatomic landmarks on panoramic radiographs in the pediatric population. *BMC Oral Health*. 2023;23(1):764.
188. Duman S, Yılmaz EF, Eşer G, Çelik Ö, Bayrakdar IS, Bilgir E, et al. Detecting the presence of taurodont teeth on panoramic radiographs using a deep learning-based convolutional neural network algorithm. *Oral Radiol* 2023;39(1):207–14.
189. Kurt A, Günaçar DN, Şılbır FY, Yeşil Z, Bayrakdar İŞ, Çelik Ö, et al. Evaluation of tooth development stages with deep learning-based artificial intelligence algorithm. *BMC Oral Health* 2024;24(1):1034.

190. Santra AK, Christy CJ. Genetic algorithm and confusion matrix for document clustering. *IJCSI* 2012;9(1):322.
191. Deng X, Liu Q, Deng Y, Mahadevan S. An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Inf Sci (NY)* 2016;340:250–61.
192. Lee JH, Han SS, Kim YH, Lee C, Kim I. Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol* 2020;129(6):635–42.
193. Tomak L, Bek Y. İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması. *J Exp Clin Med* 2011;27(2).
194. Davis J, Goadrich M. The relationship between Precision-Recall and ROC curves. In: *Proceedings of the 23rd international conference on Machine learning- ICML*, ACM Press, New York, USA, 2006:233–40.
195. Cameron AC, Widmer RP. *Handbook of Pediatric Dentistry* (5th ed.) Elsevier Health Sciences, 2021.
196. Cantín M, Fonseca GM. Dens invaginatus in an impacted mesiodens: a morphological study. *Rom J Morphol Embryol* 2013;54(3 Suppl):879–84.
197. Hülsmann M. Severe dens invaginatus malformation. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod* 1996;82(4):456–8.
198. T. Ceyhanli K, Çelik D, H. Altintas S, Taşdemir T, S. Sezgin Ö. Conservative treatment and follow-up of type III dens invaginatus using cone beam computed tomography. *J Oral Sci* 2014;56(4):307–10.
199. Munir B, Tirmazi SM, Majeed HA, Khan AM, Iqbalbangash N. Dens invaginatus: aetiology, classification, prevalence, diagnosis and treatment considerations. *Pakistan Oral & Dental Journal* 2011;31(1).
200. Whaites E, Drage N. *Essentials of Dental Radiography and Radiology*. (5th ed.) Elsevier, London, 2013:171–192.
201. White S, Pharoah M. *Oral Radiology Principles and Interpretation*. (6th ed.) Mosby; 2009:295–324
202. Kfir A, Telishevsky-Strauss Y, Leitner A, Metzger Z. The diagnosis and conservative treatment of a complex type 3 dens invaginatus using cone beam computed tomography (CBCT) and 3D plastic models. *Int Endod J* 2013;46(3):275–88.
203. Shan T, Tay FR, Gu L. Application of Artificial Intelligence in Dentistry. *J Dent Res* 2021;100(3):232–44.
204. Joda DAA. Exploring the use of AI in odontology for paediatric patients: a systematic integrative review. Master's Thesis, Instituto Universitário de Ciências da Saúde, Portugal, 2023.
205. Heo MS, Kim JE, Hwang JJ, Han SS, Kim JS, Yi WJ, et al. Artificial intelligence in oral and maxillofacial radiology: what is currently possible? *Dentomaxillofac Radiol* 2021;50(3).

206. Rodrigues JA, Krois J, Schwendicke F. Demystifying artificial intelligence and deep learning in dentistry. *Braz Oral Res* 2021;35: e094
207. Aşçı E, Kılıç M, Çelik Ö, Bayrakdar İŞ, Bilgir E, Aslan AF, et al. Automatic detection and classification of dental restorations in panoramic radiographs with artificial intelligence method developed using deep learning method: methodological studies. *Türkiye Klinikleri Journal of Dental Sciences* 2022;28(2):329–37.
208. Okazaki S, Mine Y, Iwamoto Y, Urabe S, Mitsuhata C, Nomura R, et al. Analysis of the feasibility of using deep learning for multiclass classification of dental anomalies on panoramic radiographs. *Dent Mater J* 2022;41(6):2022–98.
209. Lee S, Kim D, Jeong HG. Detecting 17 fine-grained dental anomalies from panoramic dental radiography using artificial intelligence. *Sci Rep* 2022;12(1):1–8.
210. Kang CH, Kim SY. Real-time object detection and segmentation technology: an analysis of the YOLO algorithm. *JMST Advances* 2023;5(2):69–76.
211. Redmon J, Divvala S, Girshick R, Farhadi A. You Only Look Once: unified, real-time object detection. In: *CVPR IEEE 2016*:779–88.
212. Chitraningrum N, Banowati L, Herdiana D, Mulyati B, Sakti I, Fudholi A, et al. Comparison study of corn leaf disease detection based on deep learning YOLO-v5 and YOLO-v8. *J. Eng. Technol. Sci* 2024;56(1):61–70.
213. Terven J, Córdova-Esparza DM, Romero-González JA. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS. *Mach Learn Knowl Extr* 2023;5(4):1680–716.
214. Rašić M, Tropčić M, Karlović P, Gabrić D, Subašić M, Knežević P. Detection and segmentation of radiolucent lesions in the lower jaw on panoramic radiographs using deep neural networks. *Medicina (B Aires)*. 2023;59(12):2138.
215. Karakuş R, Öziç MÜ, Tassoker M. AI-assisted detection of interproximal, occlusal, and secondary caries on bite-wing radiographs: A single-shot deep learning approach. *JIIM* 2024;1–14.
216. Sarı AH. Panoramik Radyografilerde Dens İnvajinatus Varlığının Yapay Zekâ Modelleriyle Tespiti. *Uzmanlık Tezi, Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi, Konya, 2024.*
217. Bonfanti-Gris M, Herrera A, Paraíso-Medina S, Alonso-Calvo R, Martínez-Rus F, Pradiés G. Performance evaluation of three versions of a convolutional neural network for object detection and segmentation using a multiclass and reduced panoramic radiograph dataset. *J Dent* 2024;144:104891.
218. Magat G, Altındag A, Pertek Hatipoglu F, Hatipoglu O, Bayrakdar İS, Celik O, et al. Automatic deep learning detection of overhanging restorations in bitewing radiographs. *Dentomaxillofac Radiol* 53(7), 468–477.

EKLER

EK 1. ETİK KURUL ONAYI



T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
KLİNİK ARAŞTIRMALAR ETİK KURULU

Birimi : Tıbbi Etik Kurul Başkanlığı
Kodu : 2011-KAEK-2
Sayı : 2023/448
Konu : Tıbbi Etik Kurul Kararı

10.10.2023

Sayın; Dr. Öğr. Üyesi Burcu GÜÇYETMEZ TOPAL
Afyonkarahisar Sağlık Bilimleri Üniversitesi
Diş Hekimliği Fakültesi
AFYONKARAHİSAR

İlgi: Klinik Araştırmalar Etik Kurulu'nun 10.10.2023 tarih ve 2023/448 sayılı kararı.

Sorumluluğunuzda yürütülecek olan "Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Panoramik Radyografilerde Dens İnvaginatus Tespiti" başlıklı çalışmanıza ilişkin alınan ilgi sayılı Etik Kurul Kararı ekte gönderilmiştir.

Bilgilerinizi ve gereğini rica ederim.

Prof. Dr. Dağıstan Tolga ARIÖZ
Etik Kurul Başkanı

EK:
1-İlgi sayılı karar (1 sayfa)

Ali Çetinkaya kampüsü, Afyon – İzmir Yolu 8.Km 03200 / AFYONKARAHİSAR
Ayrıntılı bilgi için irtibat: Bulent UNAL
Telefon: 0. 272.2463301 – 2463304 Faks: 0. 272.2462707
e-posta: klinikarastirmalar@aku.edu.tr

T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
KLİNİK ARAŞTIRMALAR ETİK KURULU KARARLARI

Toplantı Tarihi	10.10.2023	Toplantı Numarası	2023/10	Toplantı Saati	09:00	Etik Kurul Kodu	2011-KAEK-2
-----------------	------------	-------------------	---------	----------------	-------	-----------------	-------------

448-Dr. Öğr. Üyesi Burcu GÜÇYETMEZ TOPAL'ın sorumluluğunda yürütülecek olan "Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Panoramik Radyografilerde Dens Invaginatus Tespiti" konulu Girişimsel Olmayan Klinik Araştırmalar için başvuru dosyası incelendi. Araştırma protokolüne uyularak, Sağlık Bakanlığının 13.04.2013 tarih 28617 sayılı Klinik Araştırmalar Hakkındaki Yönetmeliği ve yayımlanan kılavuzlarında belirtilen hususlar dikkate alınarak, sorumluluk araştırmacılara ait olmak üzere araştırmanın yapılmasında etik sakınca olmadığına toplantıya katılan üyelerin **oy birliği** ile karar verildi.

EK 2. İNTİHAL RAPORU

DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKÂ ALGORİTMALARIYLA PANORAMİK RADYOGRAFİLERDE DENS İNVAGİNATUS TESPİTİ

ORIGINALITY REPORT

7%

SIMILARITY INDEX

PRIMARY SOURCES

1	dergipark.org.tr Internet	216 words — 1%
2	acikbilim.yok.gov.tr Internet	92 words — 1%
3	www.turkiyeklinikleri.com Internet	92 words — 1%
4	www.mdpi.com Internet	41 words — < 1%