

T.C.
PAMUKKALE ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ İLE
TESPİT EDİLEN MANDİBULAR İKİNCİ
MOLARLARDAKİ C ŞEKLİ KANALLARIN
PANORAMİK RADYOGRAFLAR ÜZERİNDE TESPİT
EDİLME DOĞRULUKLARININ DERİN ÖĞRENME
YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKÂ
ALGORİTMALARIYLA DEĞERLENDİRİLMESİ

Ozan UYSAL

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ
UZMANLIK TEZİ

DANIŞMAN
Prof. Dr. Hayati Murat AKGÜL

DENİZLİ-2024

T.C.
PAMUKKALE ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ İLE
TESPİT EDİLEN MANDİBULAR İKİNCİ
MOLARLARDAKİ C ŞEKLİ KANALLARIN
PANORAMİK RADYOGRAFLAR ÜZERİNDE TESPİT
EDİLME DOĞRULUKLARININ DERİN ÖĞRENME
YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKÂ
ALGORİTMALARIYLA DEĞERLENDİRİLMESİ

Ozan UYSAL

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ
UZMANLIK TEZİ

DANIŞMAN
Prof. Dr. Hayati Murat AKGÜL

DENİZLİ-2024

PAMUKKALE ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ
UZMANLIK TEZİ ONAY FORMU

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

ETİK BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmayla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.



TEŞEKKÜR

Öğrencisi olmanın gururunu yaşadığım, akademisyenliği ve insanlığıyla kendime örnek aldığım, uzmanlık eğitimim ve tezimin her aşamasında yol göstericiliğini, hoşgörüsünü, sabrını ve desteğini esirgemeyen kıymetli danışman hocam Prof. Dr. Hayati Murat Akgül'e saygı ve teşekkürlerimi sunarım.

Uzmanlık eğitimim boyunca, destekleri ve emekleri için değerli hocalarım Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Başkanımız Doç. Dr. Burak Kerem Apaydın'a ve Dr. Öğretim Üyesi Gözde Açıkgoz'e,

Tezimin metodoloji kısmında bilgi ve tecrübesini esirgemeyen, desteğini her zaman hissettiğim hocalarım Prof. Dr. Özkan Miloğlu, Prof. Dr. İbrahim Yücel Özbek ve emekleri için Arş. Gör. Merve Polat'a,

Beraber çalışmaktan büyük keyif duyduğum arkadaşlarım Dr. Öğr. Üyesi Gülfem Özlü Uçan, Dt. Ezgi Uzun, Dt. Hasret Koşar, Dt. Şeriye Mert, Dt. Oğulcan Kutlucan, Dt. Ahmet Türk ve Dt. Altan Yılmaz'a,

Beni bugünlere getiren, tüm hayatım boyunca her koşulda yanımda olan canım aileme ve dostlarıma,

Desteğini her zaman yanımda hissettiğim ve hayat yolculuğunda yanımda olduğu için kendimi çok şanslı ve özel atfettiğim sevgili eşim Gamze Elçi'ye,

Saygı ve sevgilerimle en içten teşekkürlerimi sunarım.

ÖZET

Amaç: Bu çalışmanın amacı konik ışınli bilgisayarlı tomografi (KIBT) yardımı ile eğitilmiş panoramik radyografiler üzerinde mandibular 2. molarlardaki C şekilli kanal formasyonun farklı derin öğrenme algoritmaları ile tespitini yapabilmektir.

Yöntem: Çalışmamıza Pamukkale Üniversitesi, Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı arşivinde dijital panoramik radyografisi ve konik ışınli bilgisayarlı tomografi görüntüleri bulunan ve 37 veya 47 numaralı dişlerinden en az birisinin ağız içerisinde bulunduğı 592 hastaya ait görüntüler (C şekilli kanal bulunan 289 ve C şekilli olmayan 303 panoramik radyografi) dahil edildi. C şekilli kanal bulunan 289 panoramik radyografiden tek taraflı ve çift taraflı olmak üzere 422 adet ve C şekilli kanal bulunmayan 303 panoramik radyografiden C şekilli kanal sayısıyla aynı olacak şekilde 422 adet 37 ve 47 numaralı dişler panoramik radyografide etiketlendi. Böylece C şekilli kanal bulunan ve bulunmayan 844 adetlik görüntü veri setimiz oluşturuldu. C şekilli bir kanalın varlığını doğrulamak için KIBT görüntüleri altın standart olarak kabul edildi.

Veri setimizi oluşturan 844 panoramik görüntüdeki C şekilli kanallı diş tespiti için 11 farklı derin öğrenme modelinin (InceptionV3, VGG19, Xception, ResNet152V2, EfficientNetB1, EfficientNetB0, VGG16, ResNet50, ResNet50V2, DenseNet169 ve DenseNet201) orijinal ve ön işleme yapılan panoramik görüntülerinden 37 ve 47 numaralı dişlerde (kron-kök ve sadece kök şeklinde iki ayrı grup olacak şekilde) C şekilli kanalların tespit doğruluk performansı araştırıldı. Ayrıca random majority görüntülerin karmaşıklık matris kullanılarak performans metrikleri değerlendirildi.

Bulgular: Kron ve kök veri setimizdeki orijinal ve ön işlemleri görüntüler için en yüksek ortalama doğruluk değerleri 0,885 (%88,5) ve 0,886 (%88,6), sadece kök veri setimizdeki orijinal ve ön işlemleri görüntüler için en yüksek ortalama doğruluk değerleri 0,892 (%89,2) ve 0,887 (%88,7) olarak bulundu. Kron ve kök veri ve sadece kök veri setlerindeki random majority görüntülerin en

yüksek doğruluk performans metrik sonuçları sırasıyla 0,902 (%90,2) ve 0,897 (%89,7) olarak bulundu. Kron-kök veri setindeki görüntülere ön işlem yapıldığında InceptionV3, VGG19, Xception ve ResNet152V2 derin öğrenme mimarilerinin ortalama doğruluk değeri arttı, EfficientNetB1, EfficientNetB0, VGG16, ResNet50, ResNet50V2, DenseNet169 ve DenseNet201 derin öğrenme mimarilerinin ortalama doğruluk değeri azaldı. Kök veri setindeki görüntülere ön işlem yapıldığında EfficientNetB0, ResNet50, ResNet50V2, Xception ve ResNet152V2 derin öğrenme mimarilerinin ortalama doğruluk değeri arttı; kök veri setindeki görüntülere ön işlem yapıldığında InceptionV3, EfficientNetB1, VGG16, VGG19, DenseNet169 ve DenseNet201 derin öğrenme mimarilerinin ortalama doğruluk değeri azaldı.

Sonuç: Derin öğrenme mimarilerinin kombine kullanımı ile yüksek performans değerlerine ulaşılmıştır. Çalışmamız endodontik kanal tedavilerinin başarısı açısından C şekilli kanalların tespiti için önemli bir niteliktedir ve derin öğrenme modelleri klinisyenlere yardımcı olabilecek yeterliliktedir.

Anahtar Kelimeler: C şekilli diş kök kanalı, endodontik tedavi, derin öğrenme, ön işlemler

ABSTRACT

Objective: The aim of this study is to detect the C-shaped canal formation in mandibular second molars on panoramic radiographs trained with the aid of cone-beam computed tomography (CBCT) using different deep learning algorithms.

Method: Our study included images of 592 patients with at least one of their 37th or 47th teeth present in the mouth, archived in the Department of Oral, Dental, and Maxillofacial Radiology, Faculty of Dentistry, Pamukkale University. These images consisted of digital panoramic radiographs and cone-beam computed tomography (CBCT) scans. The dataset included 289 panoramic radiographs with C-shaped canals and 303 panoramic radiographs without C-shaped canals. From the 289 panoramic radiographs with C-shaped canals, a total of 422 teeth (both unilateral and bilateral) were labeled, and an equal number of 422 teeth from the 303 panoramic radiographs without C-shaped canals were labeled. This resulted in a dataset of 844 labeled panoramic radiographs for teeth numbered 37 and 47, with and without C-shaped canals. CBCT images were considered the gold standard for confirming the presence of a C-shaped canal. To detect C-shaped canals in the 844 panoramic images comprising our dataset, the detection accuracy performance of 11 different deep learning models (InceptionV3, VGG19, Xception, ResNet152V2, EfficientNetB1, EfficientNetB0, VGG16, ResNet50, ResNet50V2, DenseNet169, and DenseNet201) was investigated. The models were applied to original and preprocessed panoramic images of teeth numbered 37 and 47, divided into two separate groups: crown-root and root-only. Additionally, the performance metrics were evaluated using confusion matrices based on random majority images.

Results: For the crown-root dataset, the highest average accuracy values for original and preprocessed images were found to be 0.885 (88.5%) and 0.886 (88.6%), respectively. For the root-only dataset, the highest average accuracy values for original and preprocessed images were 0.892 (89.2%) and 0.887 (88.7%), respectively. The highest accuracy performance metrics for random majority images in the crown-root and root-only datasets were 0.902 (90.2%) and 0.897 (89.7%), respectively. When preprocessing was applied to the crown-root dataset, the average accuracy values increased for the deep learning architectures InceptionV3, VGG19, Xception, and ResNet152V2, while they decreased for EfficientNetB1, EfficientNetB0, VGG16,

ResNet50, ResNet50V2, DenseNet169, and DenseNet201. For the root-only dataset, preprocessing increased the average accuracy for EfficientNetB0, ResNet50, ResNet50V2, Xception, and ResNet152V2, whereas it decreased for InceptionV3, EfficientNetB1, VGG16, VGG19, DenseNet169, and DenseNet201.

Conclusion: High-performance values were achieved through the combined use of deep learning architectures. Our study is significant for the detection of C-shaped canals in terms of the success of endodontic treatments, and deep learning models are sufficiently capable of assisting clinicians.

Keywords: C-shaped tooth root canal, endodontic treatment, deep learning, pre-processed images



İÇİNDEKİLER

ÖZET	I
ABSTRACT	III
İÇİNDEKİLER	V
SİMGELER VE KISALTMALAR DİZİNİ	VIII
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ	XII
1.GİRİŞ	1
2. GENEL BİLGİLER	3
2.1. C Şekilli Kök Kanalları	4
2.1.1. C Şekilli Kök Kanallarının Tarihçesi	4
2.1.2. C Şekilli Kök Kanal Yapısı	4
2.1.3. C Şekilli Kök Kanallarının Görülme Sıklığı	6
2.2. C Şekilli Kök Kanallarının Sınıflandırılması	6
2.3. C Şekilli Kök Kanallarının Teşhisi	11
2.3.1. C Şekilli Kök Kanallarının Radyografik Teşhisi	11
2.3.2. C Şekilli Kök Kanallarının Klinik Teşhisi	13
2.4. C Şekilli Kanalların Görüntülenmesinde Kullanılan Teknikler	13
2.4.1. Panoramik Radyografi	13
2.4.2. Bilgisayarlı Tomografi	15
2.4.3. Konik Işınlı Bilgisayarlı Tomografi	16
2.5. Yapay Zekâ	17
2.6. Yapay Zekâ Algoritmaları	18
2.6.1. Uzman Sistemler	18
2.6.2. Genetik Algoritmalar	19
2.6.3. Bulanık Mantık	19
	V

2.6.4. Makine Öğrenmesi	19
2.6.5. Destek Vektör Makineleri	21
2.6.6. Karar Ağacı	22
2.6.7. Lojistik Regresyon	22
2.6.8. Yapay Sinir Ağları	23
2.7. Derin Öğrenme	24
2.8. Diş Hekimliğinde Yapay Zekâ Uygulamaları	30
2.9. Diş Hekimliğinde Derin Öğrenme	31
3. GEREÇ ve YÖNTEM	37
3.1. Görüntü Veri Setlerinin Oluşturulması	37
3.1.1. Hasta Seçimi ve Görüntü Veri Kümesinin Oluşturulması	37
3.1.2. Görüntü Verilerinin Ön İşleme Süreçlerinden Geçirilmesi	39
3.1.3. Görüntü Verilerinin Kırpılması	41
3.2. Derin Öğrenme Modellerinin Eğitilmesi ve Çalışmanın Genel Akış Diyagramı	45
3.2.1. Derin Öğrenme Modelleri için Hiperparametre Ayarlamaları ve Seçimleri	51
3.3. Yapay Zekâ Performansının Değerlendirilmesi	53
3.3.1. Performans Değerlendirme Metrikleri	53
4. BULGULAR	56
5. TARTIŞMA	80
6. SONUÇ ve ÖNERİLER	101
KAYNAKLAR	104
EKLER	120
Ek 1. ETİK KURUL ONAY FORMU	

Ek 2. ÖZGEÇMİŞ



SİMGELER ve KISALTMALAR DİZİNİ

AUC: Alıcı çalışma karakteristik eğrisi altında kalan alan

BT: Bilgisayarlı tomografi

CLAHE: Kontrastla Sınırlı Uyarlanabilir Histogram Eşitleme

CNN: Konvolüsyonel Sinir Ağı

DCNN: Derin Konvolüsyonel Sinir Ağı

DCGAN: Derin Evrişimli Üretken Rakip Ağlar

DN: Doğru Negatif

DP: Doğru Pozitif

DVM: Destek Vektör Makineleri

ESA: Evrişimli Sinir Ağı

f(x): Aktivasyon Fonksiyonu

GAN: Üretken Çekişmeli Ağ (Generative adversarial networks)

GB: Gigabyte

GPU: Grafik İşlemci Birimi

Grad-CAM: Gradyan ağırlıklı sınıf aktivasyon haritaları

ICC: Sınıf İçi Korelasyon Katsayısı

KA: Karar Ağacı

KIBT: Konik Işınlı Bilgisayarlı Tomografi

kVp: Peak kilovoltaj

LR: Lojistik Regresyon

mm: Milimetre

n: Veri sayısı

p: İstatistiksel anlamlılık

RAM: Rastgele Erişimli Bellek

ReLU: Aktivasyon katmanı

RFB: Çok ölçekli alıcı alan bloklı hafif evrişimli sinir ağı

sn: Saniye

txt: Metin dosyası

w: Sinaptik ağırlık

x: Giriş sinyali

YN: Yanlış Negatif

YP: Yanlış Pozitif

YSA: Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

<u>Sekil No</u>	<u>Sayfa No</u>
Şekil 2.1. C şekil konfigürasyonuna sahip bir dişin aksiyal kesit morfolojisi	5
Şekil 2.2. Melton ve arkadaşlarının C şekilli kök kanal konfigürasyonunun sınıflaması	8
Şekil 2.3. Fan ve arkadaşlarına göre C şekilli kök kanal yapısının sınıflandırılması	9
Şekil 2.4. Fan ve arkadaşlarına göre C şekilli kök kanal yapısının radyografik olarak sınıflandırılması	10
Şekil 2.5. Yapay sinir ağının şematik gösterimi	23
Şekil 2.6. Derin öğrenmenin temsili öğrenme, makine öğrenme ve yapay zekâ ile arasındaki ilişkiyi gösteren Venn diyagramı	25
Şekil 3.1.1. Veri setindeki C şekilli görüntülerin isimlendirilme örneği	38
Şekil 3.1.2. Veri setindeki C şekilsiz görüntülerin isimlendirilme örneği	39
Şekil 3.2. C şekilli kanal görüntülerine uygulanan veri ön işleme bilateral filtreleme. A. Orijinal Görüntü, B. CLAHE Görüntü, C. CLAHE Görüntü, D. Bilateral Filtrenilmiş Görüntü	40
Şekil 3.3. C şekilli kanala sahip olmayan görüntülere veri ön işleme olarak uygulanan bilateral filtreleme. A. Orijinal Görüntü, B. CLAHE Görüntü, C. CLAHE Görüntü, D. Bilateral Filtrenilmiş Görüntü	40
Şekil 3.4. Sadece kök C şekilli kanal görüntülerine uygulanan veri ön işleme bilateral filtreleme. A. Orijinal Görüntü, B. CLAHE Görüntü, C. CLAHE Görüntü, D. Bilateral Filtrenilmiş Görüntü	40
Şekil 3.5. Sadece kök C şekilli kanala sahip olmayan görüntülere uygulanan veri ön işleme bilateral filtreleme. A. Orijinal Görüntü, B. CLAHE Görüntü, C. CLAHE Görüntü, D. Bilateral Filtrenilmiş Görüntü	41
Şekil 3.6. C şekilli kanallı örnek görüntü verisinde tüm dişin MATLAB R2021b versiyonlu kırpma programı ile kırılması	42

Şekil 3.7. C şekilli kanallı örnek görüntü verisinde sadece kök kısmının MATLAB R2021b versiyonlu kırpma programı ile kırılması	43
Şekil 3.8. C şekilli kanalsız örnek görüntü verisinde tüm dışın MATLAB R2021b versiyonlu kırpma programı ile kırılması	44
Şekil 3.9. C şekilli kanalsız örnek görüntü verisinde sadece kök kısmının MATLAB R2021b versiyonlu kırpma programı ile kırılması	45
Şekil 3.10. Derin öğrenme mimarileri ile gerçekleştirilen C şekilli kanallı dış tespit modelinin gelişim aşamalarının diyagramı	48
Şekil 3.11. On katlı çapraz doğrulama modeli	49
Şekil 4.1. Kron-kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması	57
Şekil 4.2. Kron-kök veri setindeki ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması	58
Şekil 4.3. Kron-kök veri setindeki orijinal ve ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması	59
Şekil 4.4. Kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması	61
Şekil 4.5. Kök veri setindeki ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması	62
Şekil 4.6. Kök veri setindeki orijinal ve ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması	63
Şekil 4.7. Kron-kök grubundaki majority voting için karışıklık matrisi	67
Şekil 4.8. Kök grubundaki majority voting için karışıklık matrisi	67

TABLÖLAR DİZİNİ

<u>Tablo No</u>	<u>Sayfa No</u>
Tablo 2.1. Dört kategoriye ayrılmış bazı yapay zekâ tanımları	18
Tablo 2.2. Derin öğrenme yöntemini kullanan bazı araştırmalar	33
Tablo 3.1. Veri seti dağılımı	47
Tablo 3.2. İki sınıflı bir sınıflandırıcının hata matrisi	53
Tablo 4.1. Kron-kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları	56
Tablo 4.2. Kron-kök veri setindeki ön işlemleri görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları	58
Tablo 4.3. Kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları	60
Tablo 4.4. Kök veri setindeki ön işlemleri görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları	62
Tablo 4.5. Gruplara göre majority voting sonucunu veren derin öğrenme yöntem kombinasyonları	64
Tablo 4.6. Kron-kök ve kök veri setlerinin orijinal, ön işlemleri görüntülerinin ve majority voting değerlerinin en yüksek ortalama doğruluk performans sonuçları	65
Tablo 4.7. Gruplara göre majority voting sonuçları için diğer performans sonuçları	67
Tablo 4.8. Kron-kök ve kök gruplarında yapay zekâ algoritmalarının doğruluk değerlerinin sınıf içi korelasyon (Spearman's korelasyonu) katsayısı değerleri ve istatistiksel olarak karşılaştırması	69
Tablo 4.9. Kron-kök veri setindeki yapay zekâ algoritmalarının orijinal veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması	71

Tablo 4.10. Kron-kök veri setindeki yapay zekâ algoritmalarının ön işlemleri veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması	72
Tablo 4.11. Kök veri veri setindeki yapay zekâ algoritmalarının orijinal veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması	73
Tablo 4.12. Kök veri veri setindeki yapay zekâ algoritmalarının ön işlemleri veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması	74
Tablo 4.13. Yapay zekâ algoritmalarının kron-kök veri setindeki orijinal ve ön işlemleri görüntü verileri üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması	76
Tablo 4.14. Yapay zekâ algoritmalarının kök veri setindeki orijinal ve ön işlemleri görüntü verileri üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması	78

1.GİRİŞ

Diş köklerinin sayısı ve şekli, amelocemental bağlantının altında horizontal düzlemde bükülen ve kökler için açıklıklar bırakarak merkezde birleşen Hertwig'in epitel kılıfı tarafından belirlenir. Kaynaşmış kökler, Hertwig epitel kılıfının furkasyon alanında kaynaşmamasının bir sonucu olarak zamanla sement birikimiyle oluşabilir. C şeklindeki bir kanal, gelişim sırasında mezial kanal ile distal kanalın bir kısmının birleşmesi nedeniyle kanalın tamamen birbirinden ayrılmadığı morfolojik bir durumdur.¹ En sık ikinci mandibular molar dişlerde görülür. Mandibular ikinci büyük azı dişlerinde görülen C şekilli kanal konfigürasyonunun en sık şekli, kökler arasında trabeküler paterni nispeten yaygın olan iki ayrı konik kök yapısıdır. C şeklindeki kanalların görülme sıklığının Beyazlarda %2,7 ile %9,0 arasında olduğu tahmin edilmekte iken, Çinliler ve Japonlar gibi Asyalı popülasyonlarda bu oran %31,5'e kadar yükselmektedir. Kore popülasyonunda, mandibular ikinci büyük azı dişlerinin %32,7'sinin C şeklinde bir kanala sahip olduğu belirtilmiştir.²

Klinikte karşılaşılan anatomik farklılıklardan biri olan C şekilli kök kanal formasyonuna sahip dişler; anatomik formları nedeniyle teşhis ve endodontik tedavilerin uygulanması açısından zorluklar içermektedir. C şeklindeki kanalların anatomisi ve bunun endodontik tedaviye uygunluğu ilgili dişin prognozu açısından son derece önem taşımaktadır. C şeklindeki kanal formasyonu, anatomik olarak önemli derecede farklılık gösterme eğilimindedir ve bu nedenle debridman, doldurma ve restorasyonda zorluklara neden olmaktadır.³

Yapay zekâ (YZ), insan zekasının rehberliğinde bilgisayar aracılığı ile düşünce üretebilen sistemlerdir.⁴ İnsan zekâsının hata yapabilme riskini ortadan kaldırmak için tasarlanan bu sistemleri, son yıllarda sağlık alanında kullanmak için pek çok çalışma yapılmıştır.⁴ Bu teknolojinin yaygınlaşmasındaki amaçlar arasında tanı süresini, etkinliğini, uzman kişilere olan ihtiyacı ve insan kaynaklı kusurları azaltmanın yanı sıra insan gözünün algılayamadığı durumları yazılımlarla tespit etmek sayılabilir. Son birkaç yılda diş hekimliği alanında, dijital panoramik radyografi görüntülerini içeren görevleri otomatikleştirmek için birçok YZ algoritması kullanılmaktadır. Bu teknikler, diş içeren bölgelerin

segmentasyonu, dişlerin tespiti ve sınıflandırılması, yapılan önceki tedavilerin tespiti, osteoporoz ve çene tümörlerinin teşhisi için görüntülerden kapsamlı öznitelikler çıkarabilmektedir.⁴ Kök kanal tedavisinin klinik uygulamasında diş hekimleri, hastanın dişlerini ve kök kanallarını değerlendirmek, ilgili klinik bilgileri elde etmek ve tedavi güçlüklerini tahmin etmek için radyografiler kullanır. Bununla birlikte, diş hekimleri genellikle radyolojik görüntülere dayanarak kök kanal tipini belirlemek için çok zaman ve efor harcarlar. Direk panoramik görüntülerden kök kanal tipini belirlemek zordur.⁵

Bu nedenle kök kanal tedavisinin başarısında önemli paya sahip olan mandibular ikinci molar dişlerdeki C şekilli kanal formasyonunun panoramik radyografi ve konik ışınli bilgisayarlı tomografi üzerinde tespitinde ve sınıflandırılmasında derin öğrenme mimarileri kullanılmıştır.

Yapılan literatür taramasında; C şekilli kök kanal yapısına sahip mandibular ikinci molar dişlerin YZ destekli teşhisine yönelik araştırmalar mevcut olsa da yeterli sayıda bulunmamaktadır. Yaptığımız çalışmanın amacı; konik ışınli bilgisayarlı tomografi ile mandibular ikinci molarlardaki C şekilli kanal tespitinde görülen gözlemci öznelliğinin C şekilli kanal tespitini etkilemesi, metotların çok fazla zaman ve çaba gerektiren manuel yöntemlere dayanması, metodolojik olarak gerekli örneklem büyüklükleri göz önüne alındığında rutin klinik uygulama zorluğu gibi dezavantajların üstesinden gelmenin bir yolu olarak KIBT' de saptanan mandibular ikinci molar dişlerdeki C şekilli kök kanal konfigürasyonunun dijital panoramik radyografi görüntüleri üzerinden YZ algoritmaları kullanılarak tespitidir. Böylece iki boyutlu radyografilerde teşhisi zor olan durumları YZ ile tespit ederek tanı koyma için geçen süreyi ve uzman klinisyenlere olan ihtiyacı, görüntüleme sistemleri için harcanan maliyeti ve radyasyon dozunu azaltabiliriz. Araştırmamızda 37 ve 47 numaralı dişlerde kron-kök ve kök veri setimiz kendi içinde orijinal görüntüler ve veri ön işleme yapılan görüntüler olarak iki alt gruba ayrılmış olup, bu gruplarda derin öğrenme mimarilerinin çeşitli kombinasyonları ile en yüksek doğruluk değerlerine ulaşılmaya çalışılmıştır.

2.GENEL BİLGİLER

Kök kanal tedavisinin amacı, kök kanal sistemini enfekte artıklardan ve mikroorganizmalardan temizlemek, kök kanal boşluğunu sızdırmaz bir şekilde doldurarak kök kanallarının yeniden enfekte olmasını önlemek ve yeterli bir kron üstü restorasyon ile dişin semptomsuz olarak fonksiyona katılımını sağlamaktır.⁶

Başarılı bir kök kanal tedavisi için endodontik tedavi aşamalarının kusursuz bir şekilde yerine getirilmesi gerekmektedir. Bunun yanında, doğru teşhis ve tedavi planı yapılması, klinik deneyime sahip olunması, dişlerin sık rastlanan kök kanal anatomileri ile varyasyonlarının bilinmesi ve yeterli koronal restorasyon ile sızdırmazlık sağlanması tedavinin başarısında rol oynayan diğer önemli faktörlerdir.^{1,7-9}

Hertwig epitel kök kılıfının hem bukkal hem de lingual yüzeylerde kaynaşmaması, konik veya prizma şeklinde bir kök oluşumuyla sonuçlanır.¹ Füzyon büyük olasılıkla kök kanalları arasındaki mesafe az ise meydana gelir.² Mandibular ikinci molar dişlerde C-şekilli kanal morfolojilerinin yüksek insidansı nedeniyle, bu dişlerin özellikleri, öncelikle bu kanalların sınıflaması için kullanılmıştır.¹⁰ Ortaya çıkan spesifik anatomik özelliklerin, Hertwig epitel kök kılıfının bukkal veya lingual yüzeyde kaynaşmamasına bağlı yetersiz kök ayrılması olduğu bildirilmiştir.¹⁰

Geçmişten günümüze birçok araştırmacı dişlerin morfolojik özelliklerini farklı yöntemler kullanarak incelemiş ve aralarında bazı farklılıklar bulunduğunu belirtmişlerdir.^{11,12} Kök kanal yapısının büyüklük, şekil ve oryantasyon açısından gösterdiği anatomik çeşitlilikler, tedavi basamaklarının doğru ve etkili bir şekilde uygulanabilmesi açısından oldukça önemlidir. Bu yüzden yeterli bir kök kanal tedavisi ve uzun dönem başarı için hekimler, kök kanal sistemi ve olası çeşitlilikleri hakkında kapsamlı bir bilgi birikimine sahip olmalı ve tedavi öncesi bu çeşitlilikleri tespit edebilmelidir.⁸

2.1. C Şekilli Kök Kanalları

2.1.1. C Şekilli Kök Kanallarının Tarihçesi

Kök kanal sisteminin önemli modifikasyonlarından biri “C” konfigürasyonudur. “C” olarak ifade edilmesinin nedeni kök ve kök kanal anatomisinin çapraz kesit morfolojisinde “C” şekli göstermesidir.⁹ Yapılan çalışmaların çoğu öncelikli olarak kök kanal morfolojisi ve insidans oranları, vaka çalışmaları ve antropolojik gözlemler üzerine odaklanmıştır.¹³

C şekilli kanal yapısından ilk kez, 1911 yılında Keith ve Knowles¹⁴ bahsetmiş ve çalışmaları sırasında karşılaştıkları anatomik farklılığı, spesifik bir terminoloji kullanmadan, detaylı olarak tanımlamaya çalışmışlardır. 1941 yılında Nakayama¹⁵ tarafından bu varyasyon için ilk kez “Oluk şekilli kök” ismi kullanılmıştır. Tratman¹⁶ C şeklindeki kök morfolojisinin, Asyalı bireylerde, mandibular ikinci molar dişlerde sıklıkla görüldüğünü belirtmiş ve bu morfolojiyi “at nalının küçültülmüş formu” olarak isimlendirmiştir. Cooke ve Cox¹⁷ daha sonra “C şekilli kök” ve “C şekilli kök kanalı” terimlerini endodontik literatüre kazandırmıştır. Nakayama¹⁵ oluk şekilli kök kanal morfolojisi, olası tedavi zorlukları, teşhis ve tedavi süresince dikkat edilmesi gereken prosedürler üzerinde durmuştur. Kök kanallarının tespiti, temizlenmesi ve mekanik şekillendirilmesinin zorluğundan ve perforasyon riskinden bahsetmiştir.

Melton ve ark.⁷ yaptıkları sistematik bir çalışmada, C şekilli kök kanalının farklı bireylerde belirgin değişiklikler gösterdiğini belirtmişlerdir. Kök kanallarının polyester rezin kalıpları kullanılarak C şekilli kök kanalı morfolojisinin önemli histolojik detaylarını açıklamışlardır. Cooke ve Cox¹⁷, un yanı sıra güncel çalışmaların çoğunda olduğu gibi “C şekilli kök” terimi kök morfolojisini ve “C şekilli kök kanalı” terimi ise kök kanal morfolojisini belirtmektedir.¹³


2.1.2. “C” Şekilli Kök Kanal Yapısı

Lingual veya bukkal kök yüzeyinde Hertwig epitel kınının birleşmesinde oluşan başarısızlık, genellikle C şekilli kök kanalı içeren C şekilli köklerin ana nedenidir.¹ Ayrıca C şekilli kök, sementin zamanla birikmesiyle köklerin birleşmesi sonucu da oluşabilir.¹

C şekilli kanallar mezial ve distal köklerin hem bukkal hem de lingual yüzeyleri birleştiği zaman oluşur.¹⁸

Kök kanalları boyunca korondan apikale doğru farklı konfigürasyon varyasyonları görülebilmektedir.^{19,20} Pulpa odasının tabanı derindir ve norm dışı anatomik görünümüne sahiptir. C şekilli olukta iki veya üç kanal bulunabilir veya C şekli kök boyunca devam edebilir.¹⁸

Tipik olarak, bu kanal konfigürasyonu bukkal ya da lingual yüzeyden füzyona uğramış köklerde tespit edilmektedir. Kök üzerinde füzyon bölgesinde dar bir oluk bulunabilmektedir.²¹ Ayrıca kök kanal sisteminde ayrı kök kanallarını birbirine bağlayan isthmus ve aksesuar kanal yapıları bulunabilmektedir. Dişlerin aksiyal kesit görüntüsü şerit halinde bir C şekil yapısı göstermektedir (Şekil 2.1).^{1,19,22}



Şekil 2.1. C şekil konfigürasyonuna sahip bir dişin aksiyal kesit morfolojisi

Pulpa tabanı üzerinde gözlenen C şekil yapısına sahip kanal girişlerinin kökün apikal üçte birine kadar süreklilik gösterip göstermediği belirsizdir.¹⁷ Tam bir C şekilli kök kanalında enstrüman mezialden distale doğru bir takılma olmaksızın hareket ettirilebilmektedir.^{10,23} Diğer konfigürasyonlarda C şekil yapısı küçük isthmus bağlantıları ile kesintiye uğrayabilirken, isthmus alanının altında herhangi bir seviyede yeniden bağlantı oluşabilmektedir.¹⁰ Enstrümantasyon

öncesinde iki ayrı kanal girişi olduğu tespit edilen durumlarda da; kök kanalı boyunca bağlantılar olduğu gözlenebilmektedir.¹⁰

2.1.3. C Şekli Kök Kanallarının Görülme Sıklığı

Bu anatomi beyaz ırkta ve Asyalılarda daha yaygındır.^{13,28-32} Kore popülasyonunda yapılan iki çalışmada %44,6 ve %32,7, Çin popülasyonunda %31,5, Lübnan popülasyonunda %19,4, Yunanistan popülasyonunda %5 olarak bildirilmiştir.²⁴⁻²⁸ Türkiye popülasyonunda yapılan bir çalışmada ise mandibular ikinci molar dişlerde bu oran %8,9 olarak bildirilmiştir.²⁰

Ağız içerisinde mandibular birinci molar, maksiller molar, mandibular birinci premolar ve maksiller lateral dişlerde görülmekle birlikte, en çok mandibular ikinci molar dişlerde görülmektedir.^{22,23} Yapılan araştırmalarda C şekilli kök kanal yapısının, mandibular ikinci molar dişlerde görülme sıklığının %2,7 ile %44,5 aralığında olduğu bildirilmektedir.^{23,29} Bunun yanı sıra C şekilli kanal yapısına sahip bir diş ağzın bir tarafında görüldüğünde, çoğunlukla karşıt arka da ortaya çıkar. Bilateral görülme yüzdesi ise %70-%81 olarak rapor edilmiştir. Ayrıca cinsiyet, yaş ve diş pozisyonunun C şekilli kanal konfigürasyonu ile ilişkisi yoktur.²⁹

2.2. C Şekli Kök Kanallarının Sınıflandırılması

Kök kanalları aksesuar dallanmalar ve kökün uzun eksen boyunda anastomozlar da dahil olmak üzere çeşitli şekiller sergileyebilir. Genel olarak kök kanal formu şeffaflaştırma tekniği kullanılarak incelenmiştir.^{30,31} Bu yaklaşım genellikle kök kanallarının irrigasyonu, kurutulması, kanal girişlerine Hint (veya Çin) mürekkebi enjeksiyonu, giriş kavitesinin örtülenmesi, dişlerin dehidratasyonu ve şeffaflaştırılan örneklerin stereomikroskopta incelenmesi aşamalarını içermektedir.¹³ Bu tekniği kullanarak, Vertucci³² 1984 yılında 2400 adet daimi dişte kök kanal şekillerini araştırmış ve kök kanal morfolojisi için genel bir sistem kurmuştur. Bununla birlikte polyester rezin döküm modelleri, histoloji, X-ışını görüntüleme ve daha yakın zamanda bilgisayarlı tomografi ve mikro bilgisayarlı tomografi dahil diğer teknikler de kullanılmıştır.^{7,33-35}

Genel olarak dişlerin morfolojisi bilateral simetriktir.^{36,37} Asimetrik vakalar bildirilmesine rağmen, alışılmadık kök kanal morfolojileri genellikle simetrik

olarak gözlenir.³⁸ Dankner ve ark.³⁹ maksiller birinci molar dişlerde C şekilli köklerin simetrik bulunduğunu rapor etmiştir. Fava ve ark.⁴⁰ dört maksiller ve mandibular ikinci molarların hepsinin tek bir kökle birlikte tek kök kanalının olduğu bir vakayı rapor etmişlerdir. Bilateral anatomik farklılıkların nadiren bulunmasından dolayı simetrik dişin dikkatli bir şekilde kontrol edilmesi gerektiğini tavsiye etmişlerdir.⁴⁰ Sabala ve ark.²⁹ norm dışı morfolojiye sahip vakaların neredeyse tamamının simetrik meydana geldiğini belirtmişlerdir. Nakayama¹⁵ tarafından rapor edilen 44 vakanın 11'inde (%25) C şekilli kök varlığı bilateral bulunmuştur.

Melton ve arkadaşları⁷ 1991 yılında C şekil yapısını kanalların çapraz kesit görüntülerine göre ilk kez sınıflamıştır (Şekil 2.2):

- Sınıf 1: Pulpa odasından kök ucuna kadar herhangi bir ayrılma olmaksızın uzanan sürekli C şekilli kanal yapısı.
- Sınıf 2: Ana kanalın bir mezial kanaldan dentin ile ayrıldığı ve noktalı virgül şeklinde kanal girişinin gözlemlendiği yapı.
- Sınıf 3: İki veya daha fazla ayrı ve bölünmüş şekilde gözlenen yapı.


Sınıf 3 sınıflamasını da subdivizyon 1, subdivizyon 2 ve subdivizyon 3 şeklinde üç alt gruba ayırmıştır:

Subdivizyon 1; Koronal üçlüdeki C şekil yapısı apikale doğru iki veya daha fazla kanala ayrılmakta ve apikalde birleşmektedir.

Subdivizyon 2; Koronal üçlüdeki C şekil yapısı kökün ortasından apikale doğru iki veya daha fazla kanala ayrılmakta ve bölünmektedir.

Subdivizyon 3; C şekil yapısı koronal üçlünden apikale doğru iki veya daha fazla kanala ayrılmakta ve bölünmektedir.

Bu sınıflandırmaya göre sınıf 2 ve 3 arasındaki fark belirgin bir şekilde açıklanmamıştır.⁷ Ayrıca kök kanalı boyunca C şekil yapısının gösterdiği değişiklikler ayrıntılı olarak ele alınmamıştır. Bundan başka kökü üç seviyede değerlendirmişler, bu yüzden kanal şeklinin uzunluğu boyunca nasıl değiştiğini tanımlayan bir bilgi sunamamışlardır. Ayrıca ikinci tip C şekilli kanalın en sık görülen kanal olduğunu rapor etmişlerdir.¹⁰




Şekil 2.2. Melton ve arkadaşlarının⁷ C şekilli kök kanal konfigürasyonunun sınıflaması

Bu sebeplerden dolayı güncel çalışmalarda sıklıkla 2004 yılında Fan ve arkadaşlarının²¹ önerdiği sınıflandırma kullanılmaktadır (Şekil 2.3). Fan ve arkadaşlarının¹⁹, Melton ve arkadaşlarının⁷ sınıflandırmasını modifiye ederek önerdiği anatomik sınıflandırma aşağıdaki gibidir;

- Sınıf 1: Herhangi bir bölünme ve ayrılma olmaksızın kesintisiz C formu gözlenmektedir (C1).
- Sınıf 2: C formunun kesintiye uğradığı, noktalı virgül formasyonudur. Bu sınıfta ya a ya da b açısı 60 dereceden küçük olmamalıdır (C2).
- Sınıf 3: a, b ve c açılarının hepsinin 60 dereceden küçük olduğu 2 veya 3 ayrı kanal formu gözlenmektedir (C3).
- Sınıf 4: Çapraz kesitte yalnızca bir dairesel ya da oval kanal formu gözlenmektedir (C4).

- Sınıf 5: Kanal lümeni gözlenmemektedir. Genellikle kök ucu yakınlarında görülmektedir (C5).



Şekil 2.3. Fan ve arkadaşlarına²¹ göre C şeklinli kök kanal yapısının sınıflandırılması


Şekilde C2 ve C3'te O noktası, AB düzleminin orta noktasıdır ve a, b, c ise ilgili düzlemler arasındaki açıdır.

C3 tipi kanal ağzlarının iki veya üç ayrı kanal varmış gibi görünmesinin nedeni isthmusların bu kanal girişlerini yer yer birbirine bağlamasıdır. Apekte yakın bulunan tek, yuvarlak veya oval kanalın (C4 sınıflaması), kanalın diğer bölümleri "C" konfigürasyonuna sahip olduğu için varyasyon olarak düşünülebileceğini ifade etmişlerdir. Ayrıca "C" şeklinin kök uzunluğu boyunca değişkenlik gösterebileceğini, bu yüzden klinik kuran morfolojisi veya kanal girişinin gerçek kanal anatomisi için tam olarak belirleyici faktör olmadığını belirtmişlerdir.²¹

Özellikle C1 ve C2 konfigürasyonlarında bulunan dar ve uzun “isthmus” alanlarında, kompleks anatomik özellikleri nedeniyle enfekte olmuş debris veya yumuşak doku artıkları bulunabilmektedir.^{7,19,41} C2 kategorisinde kanallardan birinin yay görünümüne sahip olduğunu ve bu kanalların şekillendirmesi ve temizlenmesinin C3 kategorisindeki kanaldan daha zor olduğunu belirtmişlerdir.²¹

Fan ve arkadaşlarının²¹ önerdiği radyografik sınıflandırma aşağıdaki gibidir (Şekil 2.4);

- Tip 1: Belirsiz radyolüsent bir çizginin kökü mezial ve distal olarak iki parçaya ayırdığı, kare veya konik şekilli kök yapısı gözlenmektedir. Apikal foramenden çıkmadan önce birleşen mezial ve distal kök kanalları bulunmaktadır (Şekil 2.4a).
- Tip 2: Belirsiz radyolüsent bir çizginin kökü mezial ve distal olarak iki parçaya ayırdığı, kare veya konik şekilli kök yapısı gözlenmektedir. Her iki kök kanalı apikal foramene kadar birleşmeden devam etmektedir (Şekil 2.4b).
- Tip 3: Belirsiz radyolüsent bir çizginin kökü mezial ve distal olarak iki parçaya ayırdığı, kare veya konik şekilli kök yapısı gözlenmektedir. Bir kök kanalı apikal foramene kadar devam ederken, diğeri radyolüsent çizgi üzerine süperpoze bir eğim göstermektedir (Şekil 2.4c).



Şekil 2.4. Fan ve arkadaşlarına¹⁹ göre C şekilli kök kanal yapısının radyografik olarak sınıflandırılması

2.3. C Şekilli Kök Kanallarının Teşhisi

Nakayama ve arkadaşları¹⁵ C şekilli kanalları, genel hatlarıyla C şekilli kökte ayrı bir kanal veya kanal girişi olmasına bakılmadan kök yüzeyinde dikey oluk varlığı bulunması şartıyla kabul etmişlerdir. Fan ve arkadaşları¹⁹ ise kanal sisteminin C şekilli olarak tanımlanabilmesi için birleşmiş kökler, kökün lingual veya bukkal yüzeyinde dikey oluk bulunması ve en az bir çapraz kesitte kanalın C1, C2 veya C3 konfigürasyonuna sahip olması özelliklerinin tümünü göstermesi gerektiğini bildirmişlerdir. C şekilli kanal morfolojisinin farklı varyasyonları tedavi sırasında zorluklara sebep olmaktadır, bu yüzden tedaviden önce doğru yapılacak olan teşhis çok önemlidir.⁴²

2.3.1. C Şekilli Kök Kanallarının Radyografik Teşhisi

C şekil yapısına sahip kanal morfolojisi tedavi sırasında bazı zorluklara neden olabileceği için, tedavi öncesi bu varyasyonun farkına varılması, aşamaların tam bir şekilde uygulanması açısından oldukça önemlidir.⁴⁵ Bu nedenle C şekilli kök kanal yapısından şüphelenilen durumlarda, 20 derece mezial ya da distalden açlandırılmış ilave radyografiler alınması yarar sağlayabilmektedir.¹²

Cooke ve Cox¹⁷ C şekilli kanalların, işlem öncesi alınacak iki boyutlu konvansiyonel radyografilerle tespit edilmesinin mümkün olmadığını bildirmelerine rağmen Fan ve ark.²¹ ve Jerome²² preoperatif radyografiler ile C şekilli kanalların tespit edilebileceğini belirtmişlerdir. C şekilli kanal tespiti için alınan radyografilerde görüntü, radiküler füzyon veya geniş bir distal kanal, dar bir mezial kanal ve bunlar arasında üçüncü bir kanalın bulanık görüntüsü şeklindedir.⁴² Bu sebeple, mandibular 2. molardaki bir C şekilli kanalın, konvansiyonel radyografide, tek bir füzyona uğramış kök veya arada bağlantısı bulunan iki ayrı kök olarak gözlenmesinin mümkün olduğu bildirilmiştir.⁴³ C şekilli kanalların kökler arası “oluk” bölgesinde dentinin ince olduğu durumlarda veya kemik trabekül yoğunluğuna bağlı olarak konvansiyonel radyografilerle tespit edilmesi güçleşebilmektedir.¹³

C şekilli kanal boyutunu belirlemek için alınan radyografilerde, kanal konfigürasyonunda iki adet karakteristik bulgu gözlenebilmektedir.^{18,22,44,45} Radyografilerde enstrümanlar ilk olarak apekte birleşme eğilimi göstermekte veya ikinci olarak furkasyon perforasyonuna benzer şekilde görüntü vermektedir.

Bu ilk radyografik görünüme C1 konfigürasyonunda karşılaşılmaması daha olasıdır.²² Furkasyon alanında enstrümanların veya dolum materyallerinin bulunmasıyla birlikte pulpa odası tabanının yeterince ayırt edilememesi, “C” konfigürasyon tanımını güçleştirmektedir.²⁸ C şekilli molar dişlerin furkasyon perforasyonlarından ayırıcı tanısı, birden fazla radyografi alınarak ortaya konulabilmektedir.²⁸ Ayrıca üçüncü jenerasyon apex bulucuların kullanılması da ayırıcı tanıda yardımcı olabilmektedir.⁷

Geleneksel radyografi tekniği günümüzde yaygın olarak kullanılmaktadır.⁴⁶ Ancak üç boyutlu yapıların iki boyuta indirgenmesi hatalı teşhislere ve birtakım varyasyonların fark edilememesine neden olabilmektedir.⁴⁶⁻⁴⁸ C şekilli kök kanal yapısına sahip dişlerden alınan radyografiler, genel bir değerlendirme için yeterince faydalı olmalarına rağmen, kök kanalı boyunca gözlenen değişiklikler, birleşme ve bölünmelerle ilgili detaylı bilgi sağlayamamaktadır.¹⁰ Üç boyutlu görüntüleme tekniklerinin kullanımı ile geleneksel radyografinin bu tür yetersizliklerinin önüne geçilebilmektedir.¹⁰

Konik ışınli bilgisayarlı tomografi (KIBT) cihazlarının kullanılmaya başlanması, dişler ve çenelerin üç boyutlu görüntülenmesine imkan vermiştir.^{49,50} Endodontik tedavi esnasında, özellikle de varyasyonların tespit edildiği durumlarda, kök kanal morfolojileri ve bunların çevre dokular ile komşuluklarının üç boyutlu olarak incelenmesi oldukça önemlidir.⁵⁰ Görsellik ile ilgili sağlayacağı avantajlar göz önünde bulundurulduğunda, KIBT’nin, endodonti alanında yaygın olarak kullanılması gereken bir teşhis aracı olduğu rapor edilmiştir.^{50,51}

Cooke ve Cox¹⁷ 1979 yılında C şekil yapısına sahip kanalların klinik olarak tanınmasını belirli ölçütlerle (pulpa tabanının anatomisi, kanama ve ayrı kanal girişleri bulunduğunda kalıcı ağrı ve hemoraji) ilişkilendirmiştir ve giriş kavitesini değerlendirerek tanıyı doğrulamanın gerektiğini vurgulamıştır. Günümüzde KIBT kullanımı ile kök kanal sisteminin üç boyutlu görüntüsü diş yapısına zarar vermeksizin kolayca elde edilebilmektedir.¹⁹

2.3.2. C Şekilli Kök Kanallarının Klinik Teşhisi

C şekilli anatomiye sahip bir dişte kron morfolojisi diğerlerinden farklı bir özelliğe sahip olmadığı için teşhiste ayırıcı bir tanı bulunmamaktadır. Fakat kökün lingual veya bukkal yüzeyindeki oluklar lokalize periodontal hastalıklar için hazırlayıcı faktör olabilir ve bu da ilk teşhis için yardımcı olabilir.²¹ Dolayısıyla kökün lingual veya bukkal yüzeyinde derin oluk mevcut ise C şekilli kanal olduğu düşünülebilir.²⁵

C şekilli kanallarda pulpa odası okluzo-apikal yönde uzamış olduğu için bifurkasyon noktası apikale yaklaşmış olabilir ya da C şeklini gizleyerek kalsifiye olabilir.¹⁷ Gerçek bir C şekilli kanalda, herhangi bir engelle karşılaşmadan enstrüman ile mezialden distale geçmek mümkündür.⁷ Diğer konfigürasyonlarda böyle bir geçiş isthmus ile engellenmektedir.⁷ Eğer ege klinik muayene sırasında pulpa tabanındaki isthmustan geçiş yapamıyorsa, klinisyen kök kanalının ayrıldığını düşünmelidir.²⁵ Fakat laboratuvar analizlerinde bu kanalların isthmus alanının hemen altında birleşiyor olabilmesi de gözlenebilen bir durumdur.²⁵

Klinik olarak C şekilli kanal operasyon mikroskobu altında incelendiği zaman, C şeklinin kanal uzunluğu boyunca devam edeceği varsayılmaz.²¹ Kanalin koronal kısımda birleşmiş, apikal alanda ise ayrılmış olabileceği gerçeğinin göz ardı edilebilmesi mümkündür.²⁵ Böyle bir durumda kanal girişinin subpulpal seviyede bağlantılı görünümde olup, apikal seviyede ayrılarak sonlanabileceğinden şüphe edilmelidir.²⁵ Bu nedenle C şekilli kanal sisteminin sadece varlığını değil, aynı zamanda bütün sistemin konfigürasyonunu teşhis etmek için yeni yöntemler geliştirilmelidir.²¹

2.4. C Şekilli Kanalların Görüntülenmesinde Kullanılan Teknikler

2.4.1. Panoramik Radyografi

Panoramik tomografi, pantomografi veya ortopantomografi olarak da adlandırılan panoramik radyografi, dişler, temporomandibular eklem, maksiller sinüsler, maksilla ve mandibula dahil olacak şekilde fasiyal yapıların tek bir film üzerinde görüntüsünün oluşmasını sağlayan bir tekniktir. Panoramik radyografi cihazlarında öncelikle görüntülenecek bölge (imaj tabakası veya focal trough) belirlenmektedir. İmaj tabakası, içerdiği objelerin net olarak görüntülendiği

bölgedir. İmaj tabakası içinde kalan bölgeler net gözlenirken, dışında kalan alanlar bulanık gözlenir. Elde edilen görüntünün kalitesi, hastanın çenesinin imaj tabakası içerisinde bulunmasına bağlıdır; hasta pozisyonu tam olarak ayarlandığında optimum kalitede görüntü elde edilir.^{52,53}

Panoramik radyografinin diğer kullanım endikasyonları arasında;

- Çocuklarda ve karışık dişlenme döneminde olan bireylerde dentisyonun değerlendirilmesi
- Dişlerin gelişim ve anomalilerinin değerlendirilmesi
- Dişsiz hastalarda protez planlaması yapılmadan önce çenelerin değerlendirilmesi
- Kist, tümör veya enfeksiyon gibi kemik içi patolojilerin değerlendirilmesi
- Dentomaksillofasiyal travma geçiren hastalarda fraktür varlığının değerlendirilmesi
- Temporomandibular eklemin değerlendirilmesi
- Maksiller sinüs, burun septumu ve nazal konkaların değerlendirilmesi
- Maksillofasiyal gelişim bozukluklarının incelenmesi yer almaktadır.⁵²⁻⁵⁵

Panoramik radyografinin avantajları;

- Yüz kemiklerini ve dişleri içeren kapsamlı bir görüntüleme alanının olması
- Tüm ağız serilerine göre düşük radyasyon dozu
- Uygulamasının kolay olması
- Kısa sürede görüntü oluşması
- Hızlı ve kullanışlı olması
- Non-invaziv olması
- Trismus, bulantı refleksi veya herhangi bir nedenle ağızını açamayan hastalarda kullanılabilmesi
- Hasta eğitimi açısından kolay anlaşılır olması

Panoramik radyografinin dezavantajları;

- Düşük çözünürlüklü görüntüler oluşturmamasından dolayı intraoral radyografilere kıyasla elde edilen netliğin az olması
- Küçük çürüklerin teşhisi ve periapikal hastalıkların değerlendirilmesinde yetersiz olması
- Servikal vertebralar gibi yapıların süperpoze olmaları nedeniyle odontojenik durumların değerlendirilememesi
- İmaj tabakasının dışında kalan bölgelerin bulanık görüntülenmesi
- Eşit olmayan magnifikasyon ve geometrik distorsiyon nedeniyle doğrusal ölçümlerin güvenilir olmaması
- Periapikal radyografi cihazlarına göre pahalı olması
- Hastanın maksilla ve mandibula uyumsuzluğu şiddetli ise tekniğin uygulanmasının zor olması.⁵²⁻⁵⁵

2.4.2. Bilgisayarlı Tomografi (BT)

1972’de Hounsfield tarafından geliştirilen BT, vücudun istenilen belirli bir bölgesinden kesit şeklinde geçen X-ışınlarının atenüasyonlarının dedektörlerle ölçülerek bilgisayar yardımıyla görüntü oluşturulmasıdır. Basit formdaki BT cihazı ince kolime edilmiş, yelpaze şeklinde X-ışını tüpü içermektedir. X-ışınlarının iyi kolime edilmesinden dolayı ışınların saçılması minimal seviyededir. X-ışını vücutta incelenecek bölgeye gönderilerek dedektörler aracılığıyla farklı gri renk tonlarında görüntü elde edilir. Maksillofasiyal bölgede görülen enfeksiyon, kist ve tümörlerin tanısında, gömülü dişlerin çevre anatomik yapılarla ilişkisinin değerlendirilmesinde ve travma olgularında kullanılır.⁵³⁻⁵⁷

Bilgisayarlı tomografinin avantajları;

- İstenilen alanın kesitsel görüntüsünde bölgedeki her yapı görüntülenir.
- Kesitsel görüntü oluşturmamasından dolayı istenen dokuların dışındaki bölgeler süperpoze olmaz.
- Vücudun kesit şeklinde istenilen alanının görüntülenmesi ve çok küçük kontrast farklılıklarını ayırt edebilmesinden dolayı iki boyutlu radyograflara göre çok daha fazla ayrıntı gösterir.

- Görüntüler sayısal verilerden oluşur. Bu özelliği sayesinde görüntü işlenebilir, farklı düzlemlerde veya üç boyutlu görüntüler elde edilebilir.
- Görüntüler bilgisayar ortamında saklanabilir, hasta tarafından taşınabilir.
- İki boyutlu radyograflarda aynı yoğunlukta görülen su ve yumuşak dokular, bilgisayarlı tomografide birbirinden ayırt edilebilir.
- Kemik yapıyı çok iyi görüntüleyerek kemik hacmi ve yüksekliği hakkında bilgi verir.
- İncelenecek alan bilgisayar yardımıyla ölçülebilir, ekranda büyütülebilir.

Bilgisayarlı tomografinin dezavantajları;

- Pahalı bir cihaz olmasından dolayı her merkezde olmayabilir.
- Elde edilen kesitlerden daha uzaktaki lezyonlar gözden kaçabilir.
- Metalik yabancı cisimler (küpe, restorasyonlar, protezler gibi) artefakt oluşturur.
- Çok sayıda kesit alınması nedeniyle radyasyon dozu yüksektir.
- Manyetik rezonans görüntülemeye göre yumuşak dokuyu ayırt edebilmesi daha düşüktür.^{52-54,56,57}

2.4.3. Konik Işınlı Bilgisayarlı Tomografi (KIBT)

KIBT, medikal BT'nin kompakt, daha hızlı ve güvenli bir çeşidi olup maksillofasiyal yapıların görüntülenmesinde panoramik radyografiden sonraki en önemli teknolojik gelişmedir. BT'den farklı olarak KIBT'de konik şeklinde X-ışını demeti kullanılır. Multiple rotasyonlar yerine, görüntülenmek istenen alanın etrafında 360 derece tek bir rotasyon vardır, bu sayede hastanın ışınlanma süresi azaltılır ve aldığı radyasyon miktarı düşer. KIBT'de incelenmek istenen alanın boyutuna göre görüntüleme alanı seçilir. Küçük inceleme alanlarında yüksek çözünürlükte ve daha az radyasyon dozu ile görüntüler elde edilir.^{53-55,57}

Dental implant uygulamalarında, kök-kanal morfolojisinin incelenmesinde, maksiller sinüs incelemesinde, bazı tükürük bezi patolojilerinin değerlendirilmesinde, patolojilerin tanısında, sınırlarının belirlenmesinde, gömülü ve süpernümerer dişlerin yerlerinin tespitinde ve komşu anatomik yapılarla ilişkisinin belirlenmesinde, temporomandibular eklem yapısının incelenmesinde, maksillofasiyal travma olgularında kullanılmaktadır.^{55,58}

Panoramik radyografiden farkı; geometrik distorsiyona uğramamış gerçek boyutta ve üç boyutlu görüntü sağlamasıdır.⁵⁸

KIBT'ın BT'ye göre avantajları;

- Küçük voksel boyutlu olmasından dolayı çözünürlüğü BT'ye göre daha fazladır.
- Daha ucuzdur ve daha az alan kaplar.
- Radyasyon dozu, genellikle dış bölgesinin incelendiği BT taramalarından daha düşüktür. Ancak KIBT ve BT görüntülemeleri, ekspozur parametrelerine bağlı olarak farklı radyasyon dozu etkilerine sahiptir.

KIBT'ın BT'ye göre dezavantajları;

- KIBT daha düşük kontrasta sahiptir.^{55,59}

2.5. Yapay Zekâ

Uzun bir geçmişi olduğu bilinen YZ'nin kökeni Leonardo da Vinci'nin insana benzer bir robot tasarlamak için 1495'te çizdiği eskizlere ve Antikythera mekanizması gibi antik Yunan makinelerine dayandığı belirtilmektedir.^{60,61} Ancak günümüzdeki YZ'nin Amerikalı Bilim Kurgu yazarı Isaac Asimov'un "Runaround" isimli kısa öyküsünden geliştiği düşünülmektedir. 1942'de yayınlanan öyküde mühendis Powell ve Donovan tarafından geliştirilen bir robotun hikayesi anlatılmaktadır. Bu hikâyeye; yapay zekâ, robotik ve bilgisayar bilimi alanında birçok bilim insanına özellikle Marvin Minsky'ye (MIT Yapay Zekâ Laboratuvarı'nın kurucusu) ilham verdiği belirtilmektedir.⁶² 1950'de "Mind" adlı felsefe dergisinde Alan Turing'in "Hesaplamalı Makineler ve Zekâ" isimli makalesinde akıllı makineleri test etmeye yarayan "Turing Testi"nden bahsedilmiştir. Bilgisayar biliminde bulunan YZ problemlerinin mimari ve mantıksal düşünce açısından temelini oluşturan Turing testi, günümüzde hala yapay zekâ sistemini test etmede kullanılmaktadır.⁶³⁻⁶⁵

"Yapay Zekâ" sözcüğü ise ilk kez 1956 senesinde Dartmouth Koleji'nde sekiz hafta süren bir çalışma grubunda John McCarthy tarafından kullanılarak yeni bir bilim alanı olan YZ doğmuştur.^{62,66} 1950'lerden günümüze YZ, mantık ile

felsefe alanlarındaki bilgileri gözden geçirip özetleyerek bilgi teknolojisi-sibernetik, sağlık, istatistik ve matematik alanlarında sayısız buluşla desteklenerek büyük bir ilerleme kaydetmiştir.^{61,67}

Yapay zekânın birden çok tanımını yapmak mümkündür.⁶⁸

Tablo 2.1. Dört kategoriye ayrılmış bazı yapay zekâ tanımları

İnsan gibi düşünen sistemler	Rasyonel düşünen sistemler
“Öğrenme, karar verme ve problem çözme içeren insan düşünme yetenekleriyle ilişkili etkinliklerin otomasyonu.” (Bellmann, 1978) “Bilgisayarların düşünmesinin sağlanmasında heyecan verici yeni çaba... tam ve gerçek anlamda zihinleri olan makineler.” (Haugeland, 1985)	“Bilişimsel modellerin kullanımı yoluyla zihinsel yeteneklerin incelenmesi.” (Charniak ve McDermott, 1985) “Algılamayı, akıl yürütmeyi ve hareket etmeyi mümkün kılan hesaplamaların incelenmesi.” (Winston, 1992)
İnsan gibi davranan sistemler	Rasyonel davranan sistemler
“İnsanlar tarafından yapıldığında zekâ gerektiren işlevleri gerçekleştiren makineler yaratma sanatı.” (Kurzweil, 1990)	“Bilişimsel Zekâ, akıllı ajanların tasarımının incelenmesi.” (Poole ve ark., 1998) “Yapay zekâ, objelerdeki akıllı davranışlarla ilgilidir.” (Nilsson, 1998)

2.6. Yapay Zekâ Algoritmaları

Yapay zekâ, hesaplama özelliği sayesinde psikolojiden; algı, akıl yürütme ve eyleme geçme özelliği ile de bilgisayar biliminden farklı yapıdadır. Daha akıllı ve kullanışlı makineler meydana getirir. Yapay sinir ağı ile bilimsel teoremlerin yardımıyla çalışır. Günümüzde yapay zekâ teknolojisi, her alanda pratik faydalar sunacak hale gelmektedir.⁶⁹

2.6.1. Uzman Sistemler

Uzman sistemler, sınırlı bir alandaki uzmanın veri ile ilgili problemleri çözmedeki yeteneğini taklit eden, iyi organize edilmiş bilgi gövdesine sahip bilgisayar yazılımlarıdır.⁷⁰ Bir uzman sistem, bir bilgi tabanı ve çıkarım motorundan oluşmaktadır.⁷¹ Uzman sistemlerin karar verdiği alanda yeni bilgilerin ortaya çıkması durumunda uzman tarafından yeni kurallar sisteme tanıtıldığı için bu sistemlere “kural tabanlı sistemler” veya “bilgi tabanlı sistemler” adı da

verilmektedir.⁷² Uzman sistemlerin verilerinden öğrenme olmaması ve iki değerli bir mantığın yetersiz olması nedeniyle başarısı sınırlanmaktadır.⁷¹

2.6.2. Genetik Algoritmalar

Uzman sistemler, tek bir problemin çözümünde etkilidir. Ancak, hızlı değişen durumların olduğu alanlarda sürekli yeni özellik tanımlama zorunluluğu, araştırmacıları değişebilen kuralların olduğu sistemler tasarlamaya yönlendirmiştir. Genetik algoritmalar, problemlerin çözümünde doğru veya yaklaşık olarak doğru çözümler bulmada, evrimden esinlenerek doğal seleksiyon, kalıtım gibi özellikleri temel alarak oluşturulan bir hesaplama modelidir.⁷³⁻⁷⁵ Bu algorithmada biyolojide olduğu gibi mutasyon ve çaprazlama olmak üzere iki ayrı temel fonksiyon vardır. Genetik algoritmaların uygulandığı problemlerin aralığı oldukça geniş olmasına rağmen, genetik algoritmalar genellikle fonksiyon optimize edici olarak görülür.⁷⁵ Bir etki alanı üzerinde en uygun çözümü bulmaya yardımcı olmakla birlikte yol planlama, sera iklim kontrolü, modelleme ve sınıflandırma gibi farklı alanlarda uygulanmaktadır.⁷⁶

2.6.3. Bulanık Mantık

Girdi ile çıktı verileri arasındaki ilişkinin bir transfer fonksiyonu ile ifade edilmesinde doğru matematiksel bir model seçilmesi sırasında verinin çok karmaşık olması ve netlik içermemesi durumunda uygun modeli seçmek zordur. Verinin belirsizlik içermesi halinde bulanık mantıkla modeller entegre edilerek performans artırılmaya çalışılır.^{77,78} Bulanık sistemler yaklaşık muhakemeye ve kesin olmayan bilgileri kullanarak tahmini değerlerle karar vermeye yardımcı olması nedeniyle denetim sistemleri, robotik, otomasyon, bilgi depolama ve yeniden çağırma, görüntü işleme, fonksiyon optimizasyonu gibi çeşitli alanlarda tercih edilmektedir.^{77,79}

2.6.4. Makine Öğrenmesi

Makine öğrenmesi, sunulan verilerden kendi kendine öğrenebilen, programlanmadan tahmin yapabilen, karar verebilen ve örnek verilere dayalı matematiksel bir model oluşturan algoritmalar olup YZ'nin bir alt kümesidir.^{80,81} Makine öğrenmesinde uygulamalar, programlanmadan verilerden öğrenebilir, çeşitli araçları kullanarak tahminler ile tavsiyelerde bulunabilir ve bilgisayar uygulamalarının performanslarını iyileştirmesini sağlayabilir.^{80,82} Makine

öğrenmesinde, sinir ağlarında, destek vektör makinelerinde ve evrimsel hesaplamada genellikle bir eğitim seti ve bir test seti verilir. Eğitim seti, etiketli kümenin ve makine öğrenenlerin kullanabileceği etiketlenmemiş örnek kümesidir. Test seti ise daha önce hiç görülmemiş örneklerden oluşan kümedir. Makine öğrenmesi, eğitim setini öğrenerek bir sınıflandırıcı oluşturmayı ve ardından test seti aracılığıyla sınıflandırıcının performansını değerlendirmeyi amaçlar.⁸¹

Makine öğrenmesi teknolojisi web aramalarından sosyal ağlarda içerik filtrelemeye, e-ticaret sitelerinde önerilere kadar modern toplumun birçok alanına katkı sağlar. Makine öğrenimi sistemleri, görüntülerdeki nesneleri tanımlamak, konuşmaları yazıya dönüştürmek, haber öğelerini, gönderileri veya ürünleri kullanıcıların ilgi alanlarına göre eşleştirmek için kullanılmaktadır.⁸³

Makine öğrenmesinde verilerden anlamlı ilişkiler çıkarmak için denetimli öğrenme, denetimsiz öğrenme, destekleyici öğrenme ve hibrit öğrenme gibi öğrenme kuralları kullanılmaktadır.^{84,85}

Denetimli (öğretmenli) öğrenmede, modelde girdi verisinin yanında elde edilmek istenen çıktı verisinin de sağlandığı bir öğrenme yaklaşımıdır. Çıktı verilerinde elde edilen değerlerin istenilen değerlerde olup olmadığı karşılaştırılmaktadır.⁸⁴ Örneklemdaki veriler kullanılarak bilinen sınıflar arasında kesin bir alan belirlemeye çalışılmakta ve yeni verinin hangi sınıfa ait olduğu tahmini yapılmaktadır.⁸⁶ Denetimli öğrenmede en basit model regresyon modelleridir.⁶⁸ Denetimli öğrenme modelleri:

- Doğrusal regresyon
- Lojistik regresyon
- Yapay sinir ağları
- K-en yakın komşular
- Destek vektör makineleri
- Karar ağacı
- Rastgele orman

Denetimsiz (öğretmensiz) öğrenme, sisteme sadece problemle ilgili girdi verileri verilmektedir. Model girdi verisinin yapısına bağlı olarak kendi kendine öğrenme işlemini gerçekleştirmektedir. Sınıflar belli olmadığından öncelikle veriler analiz edilerek sınıflar oluşturulur, daha sonra yeni verilerin hangi sınıfa ait olduğu tahmin edilir.^{84,86}

Destekleyici (takviyeli) öğrenme sistemlerinin denetimli ve denetimsiz öğrenme yöntemlerine benzer yönleri bulunmaktadır. Modele denetimsiz öğrenme olduğu gibi probleme ait sadece girdi verileri verilmektedir. Ancak, sistem için bir danışman bulunarak çıktı verilerinin doğru veya yanlış olduğu gösterilmektedir.⁸⁷ Bu öğrenme amaç, çevre ile etkileşime dayalı performansı artıran bir sistem geliştirmektir.⁸⁸ Bu öğrenme modeli robotik alanda kullanılmaktadır.⁶⁸

Hibrit öğrenme hem denetimsiz hem de denetimli öğrenme tekniklerini içerir. Asıl amacı sınıflandırma yapmaktır. Bu yüzden literatürde hibrit modelde genellikle denetimsiz öğrenme, denetimli öğrenmeye yardımcı olacak şekilde uygulanmaktadır.⁸⁹

2.6.5. Destek Vektör Makineleri

Destek vektör makineleri (DVM) çeşitli disiplinlerden farklı veri kategorilerini sınıflandırmak için eğitilmiş bir denetimli öğrenme tekniğidir. Büyük veri sınıflandırma problemlerinin çözülmesine yardımcı olabilecek klasik makine öğrenme tekniklerinden biridir.^{90,91}

DVM, çok boyutlu bir uzayda bir sınıfın konusunu diğerinden ayıran hiper düzlemler (karar sınırı) oluşturarak sınıflandırma yapmayı amaçlamaktadır. İkili sınıflandırmada, sınıfları ayırt etmede sınıflar arası mesafe oldukça önemlidir. Aynı sınıftaki nesnelerin mesafesi birbirine yakın hale getirilirken, farklı sınıflardaki nesnelerin mesafesi birbirinden uzaklaştırılır. Düşük boyutlu uzayda doğrusal olmayan problemlerde bu mesafenin ölçülmesi mümkün değildir. Bu nedenle probleme doğrusal olmayan dönüşümler uygulayıp problem doğrusal olarak ayrılabilir bir duruma getirilerek, daha yüksek boyutlu uzaya transfer edilip mesafelerin ölçülmesi mümkün hale gelir. DVM, birden çok kategorik değişkenleri işleyebildiğinden regresyon ve sınıflandırma görevini birlikte

yapabilmektedir. DVM, nesne tanıma ve görüntü işleme uygulamalarında sıklıkla kullanılmaktadır.^{90,91}

2.6.6. Karar Ağacı

Yapay öğrenmenin yöntemlerinden biri olan karar ağacı (KA), basit ancak çok güçlü bir analiz metodudur. Tekrarlanan sınıflandırma olarak da bilinen KA, birkaç girdi değişkenine dayalı olarak öngörücü algoritmaların geliştirilmesinde kullanılan denetimli bir öğrenme tekniğidir.⁹²

KA modelinin akış şeması ağaç yapısına benzeyen düğüm, dal ve yapraklardan oluşur. Her düğümün sıralaması, doğruluk açısından çok önemli olan “öznitelik seçimi” adı verilen matematiksel bir yaklaşım kullanılarak yapılmaktadır.⁹³

KA, tıbbi araştırmalarda çeşitli potansiyel uygulamaları olan sınıflandırma, tahmin ve yorumlamada kullanılan etkili bir yöntemdir. Araştırma sonuçlarını tanımlamada orijinal girdi değişkenlerini önemli alt gruplara bölerek girdi ve hedef değişkenler arasındaki kompleks ilişkileri basitleştirmesi, anlama ve yorumlamasının kolay olması, parametrik olmayan yaklaşıma sahip olması gibi çeşitli avantajlara sahiptir.⁹³

KA, özelliklerin tanımlanmasında, sınıflar arası bilgilerin gelecekteki deneyler ve veri analizleri tasarımının desteklemesinde kullanılabilir.⁹⁴

2.6.7. Lojistik Regresyon


Lojistik regresyon (LR), bağımlı değişkenin ikili değişkenlerle ölçüldüğü problemleri analiz etmede kullanılan istatistiksel bir tekniktir. Bu modeller, kişi düzeyindeki bilgileri kullanarak klinik sonucu tahmin etmeyi amaçlar. Örneğin, kişide hastalık varlığı veya hastalığın prognozunu tahmin etmede LR kullanılmaktadır.^{95,96}

LR, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi matematiksel bir fonksiyon kullanarak modellemektedir. Meydana gelme olasılığı bağımlı değişken iken, meydana gelmeyi tahmin etmede kullanılan özellikler veya nitelikler bağımsız değişkenlerdir. LR’de özelliklerin belirsizlik içermesi durumunda veya bağımlı değişkenin “evet-hayır” yerine “çok az, az, ortalama, fazla, çok fazla” gibi

günlük konuşma dilindeki terimlerle çoklu bir şekilde ifade edilmesi durumunda LR'nin performansı “Bulanık Mantık” ile desteklenerek artırılabilir.⁹⁷

2.6.8. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan merkezi sinir sisteminde yer alan sinir hücrelerinin (nöron) matematiksel modellerinin genellemeleri olan bilişimsel ağlardır. İnsan beyni, birbirine bağlı on milyardan fazla nörondan oluşur. Her bir nöron bilgiyi almak, işlemek ve iletmek için biyokimyasal reaksiyonları kullanan hücredir. Biyolojik sinir ağlarına benzer şekilde YSA da yapay nöronlardan oluşmaktadır. Yapay bir nöronun öğrenme yeteneği, veri ağırlıklarının seçilen öğrenme algoritmasına göre ayarlanmasıyla sağlanır.⁹⁸⁻¹⁰⁰ Sadece girdi ve çıktı katmanını bulanan yapay bir nöronun yapısı Şekil 2.5'te gösterilmektedir.



Şekil 2.5. Yapay sinir ağının şematik gösterimi

YSA'da ileri beslemeli ve geri beslemeli olmak üzere iki farklı yayılma kuralı kullanılmaktadır. İleri beslemeli ağlarda veri akışı girdi biriminden çıktı birimine doğrudur, veri işleme birden çok katmana yayılabilir, ancak geri besleme bağlantısı yoktur. Geri beslemeli ağlarda ise çıktı ve ara katmandaki çıktıların, bir önceki katmanlara geri beslenmesi durumu vardır. Tekrarlayan ağlar geri besleme bağlantıları içermektedir. Bu ağ yapısında, ağ çıktısı aynı zamanda girdi olarak da kullanılabilir.^{87,99}

YSA'nın avantajları; insan sinir sistemi gibi problemleri çözebilmek için öğrenebilme yeteneğinin bulunması, paralel çalışan karmaşık işlevleri basit şekilde çözebilmesi ve hızlı bir şekilde sonuç üretebilmesidir. YSA'nın bir başka üstün

tarafı da ayrı ayrı elemanlardan oluşan hasarın, analiz başarısında önemli bir azalmaya neden olmaması ve genellikle genel performansı etkilememesidir.¹⁰¹

YSA genellikle tahmin, sınıflandırma ve veri işleme-yorumlama-filtreleme problemlerinde uygulanmaktadır. Robotik alanda, sistem modelleme, ses tanıma, el yazısı tanıma, parmak izi tanıma, hava durumu tahmin etme, sağlık alanında teşhis, tahmin veya yorumlama, uçuş simülasyonları, sinyal-görüntü işleme, dil tercüme etme vb. gibi geniş sektörlerde uygulanmaktadır.⁸⁷


2.7. Derin Öğrenme

Yakın zamana kadar, sinyal işleme tekniği ve makine öğreniminde genellikle doğrusal olmayan dönüşüm içeren ve en fazla iki katmandan oluşan basit yapıli mimariler kullanılmıştır. Bu mimarilerin birçok problemi çözmede işlevi bulunmasına rağmen günlük hayatta konuşma, ses ve dil gibi doğal uyaran içeren daha karmaşık olan verilerde yetersiz kalmaktadır.^{80,89}

Verilerin daha karmaşık bir durumunun olması ve sayısının artması nedeniyle YSA'nın öğrenme performansının artırılması yönünde birçok yaklaşım geliştirilmiştir. Bu yaklaşımlardan biri de derin öğrenmedir. Derin öğrenme sayesinde daha karmaşık verilerin ve görüntülerin işlenmesi mümkün hale gelmiş ve karmaşık nesnelerin segmentasyonundan kaynaklanan hataların ve yanlış özellik hesaplamalarının önüne geçilmiştir.^{80,89}

Derin öğrenme, makinelerin sinir ağlarının yapısından esinlenerek algoritmaları kullanmasına izin veren makine öğreniminin bir alt alanıdır.^{80,89} Klasik makine öğrenme teknikleri ile bir model tanımlama veya makine öğrenimi sistemi kurmak için öncelikle özellik vektörünün çıkarılması gerekmektedir. Özellik vektörünün çıkarılması için alanında uzman kişilere ihtiyaç duyulmaktadır. Bu işlemler hem çok zaman almakta hem de uzmanı çok meşgul etmektedir. Bu sebeple bu teknikler, ham bir veriyi ön işlem yapmadan ve uzman yardımı olmadan işleyemezler. Derin öğrenme makine öğrenimi alanında çalışanların uzun yıllar boyunca uğraştığı bu sorunu ortadan kaldırarak büyük ilerleme kaydetmiştir. Çünkü derin ağlar geleneksel makine öğrenmesi ve görüntü işleme tekniklerinden farklı bir yaklaşım sunarak öğrenme işlemini ham veri üzerinde yapmaktadır. Ham veri üzerinde ön işleme olmadan ve farklı katmanlarda

özellik oluşturma sayesinde kompleks görüntüler üzerinde kullanılabilir. ¹⁰² Derin öğrenme tekniğinin diğer YZ teknikleri ile arasındaki ilişkisi “Venn diagramı” ile gösterilmektedir (Şekil 2.6). ¹⁰³



Şekil 2.6. Derin öğrenmenin temsili öğrenme, makine öğrenme ve yapay zekâ ile arasındaki ilişkiyi gösteren Venn diyagramı

Derin öğrenme, çok katmanlı sinir ağlarını kullanarak örnek verilere dayalı olan kalıpları sınıflandırmak için kullanılmaktadır. Piksel kümesinden oluşan nesne görüntüsünün ve insan sesinin bilgisayarlar tarafından anlaşılması, veri kümesinin bir nesne ile eşleşmesi çok zor bir işlemdir. Derin öğrenmede bu karmaşıklık hiyerarşilere bölünerek kolaylıkla gerçekleştirilir. ^{71,103}

Literatürde derin öğrenme sinir ağları, tipik olarak pikseller veya kelimeler gibi yapıları temsil eden bir dizi “girdi” katmanından, gizli birimleri içeren çok sayıda “gizli” katmandan ve bu düğümler arasında çalışan bağlantılarla bir dizi “çıktı” katmanından oluşur. Gizli katman denilmesinin nedeni, verideki değerler yerine modeli belirlemede gerekli olan verideki ilişkileri anlamaya yarayan kavramlar içermeleridir. ^{71,103}

Derin öğrenme ağlarının çoğu ağdaki sinirsel bağlantıları doğal olarak yakalayacak şekilde kısıtlayan “**evrişim (konvolüsyon)**” adı verilen bir teknikten faydalanır. ¹⁰⁴ Derin öğrenmenin temel mimarisi “**evrişimli sinir ağı (ESA)**”dır. ESA’da ardışık yerleştirilen birden fazla eğitilebilir bölümler vardır. Girdi verileri

alındıktan sonra katman katman işlemler yapılarak eğitim süreci gerçekleştirilir ve sonunda doğru sonuç ile karşılaştırmada final verisi elde edilir. Üretilen sonuç ile istenen sonucun farkı kadar bir hata oluşur. Ağ çok fazla hata yaptığında kayıp yüksek, daha az hata yaptığında ise kayıp düşüktür. Yapılan hatanın bütün ağırlıklara aktarılmasında “geri yayılım algoritması” kullanılır.⁸³ ESA’da her birim önceki birimlerin küçük bir alt kümesinin veri sonucu olurken, sonraki birimlerin ise küçük bir alt kümesinin veri setini oluşturur. Karışma daha az olur ve böylece eğitim süreci daha hızlı gerçekleşir.⁷¹

ESA’lar görüntü sınıflandırma, nesne tanımlama, görüntü segmentasyon gibi problemlerde başarıyla uygulanmaktadır. ESA’lar YSA’ların geliştirilmiş halidir. YSA’lardaki gizli katman sayılarının daha da arttırılması sonucu derinleşen ağ ESA olarak tanımlanabilir. Derinlikteki bu farklılığa ek olarak ESA’lar hiyerarşik bir yapıda öğrenme işlemini gerçekleştirir. Son olarak, ESA’ları YSA’lardan ayıran temel fark, ESA’ların derinleşen ağ yapısının eğitilmesi aşamasında ezberlemeyi önlemek için kullanmış olduğu DropOut yöntemidir. Bu yöntem, eğitim aşamasında her tekrarda ağa ait bazı düğümleri gelişigüzel kaldırarak ezber ve tekrarı önlemeyi amaçlamaktadır.¹⁰⁵

ESA’yı oluşturan katmanlar:

a. Girdi katmanı (Input layer): İlk katmandır ve veriler ham veri olarak ağa verilmektedir. Tasarlanan modelin başarısında verilen verinin boyutu önemlidir. Girdi katmanında görüntü boyutu yüksek seçilirse bellek ihtiyacı, eğitim süresi ve görüntü başına düşen test süresi uzar ve ağ başarısı artabilir. Düşük seçilirse bellek ihtiyacı ve eğitim süresi azalır, ancak kurulan modelin performansı düşük olabilir. Görüntü analizinde, ağ derinliği, hesaplama maliyeti ve ağ başarısı için girdi katmanında uygun bir görüntü boyutu seçilmelidir.^{102,106}

b. Konvolüsyon katmanı (Convolution layer): ESA’nın temel bileşenlerinden biri olup, “dönüşüm katmanı” olarak da adlandırılmaktadır. Dönüşüm işlemi, belirli bir filtrenin tüm görüntüler üzerinde dolaştırılmasına dayanır. Filtreler katmanlı mimarinin önemli bir parçası olup farklı boyutlarda seçilebilir. Filtreler, bir önceki katmandan gelen girdi verilerine konvolüsyon uygulayarak çıktı verisi meydana getirir ve işlem sonucu aktivasyon (özellik) haritası oluşur. Aktivasyon

haritası, her filtreye özgü özelliklerin bulunduğu yerdir ve buradaki değerler, girdi ve çıktı boyutu arasında aynı yoğunluk aralığını sağlamak için normalize edilmektedir. ESA'ların eğitimi esnasında bu filtrelerin katsayıları, eğitim kümesindeki her öğrenme iterasyonu ile değişir. Böylelikle ağı, verinin hangi bölgelerinin önem taşıdığını belirleyerek özellik çıkarabilir.¹⁰⁷

c. Aktivasyon katmanı (Rectified linear units layer-ReLu): ReLu, ESA'nın çıktıları için en yaygın şekilde kullandığı "doğrultucu birimi"dir. Girdi verisinde negatif verileri sıfıra çekerek çalışır. Bir önceki katmanda gerçekleştirilen belirli matematiksel işlemlerden dolayı ağı doğrusaldır, derin ağı doğrusal olmayan bir yapıya sokmak için bu katman uygulanır. Bu katmanla birlikte ağı karmaşık özellikleri daha hızlı öğrenir ve eğitim süreci daha verimli hale gelir.¹⁰²

d. Havuzlama katmanı (Pooling layer): Sonraki konvolüsyon katmanı için girdi boyutunu (genişlik x yükseklik) azaltırken, verinin derinlik boyutunu etkilemez. Boyuttaki azalma bilgi kaybına yol açar. Bilgi kaybı, ağı katmanlarının hesaplama yükünü azaltması ve sistemin ezberlemesini önlemesi nedeniyle faydalıdır. Bir önceki katmanda olduğu gibi bu katmanda da belli filtreler görüntülere tanımlanarak görüntüdeki piksellerin en büyük değerlerini (maksimum havuzlama) veya değerlerin ortalamasını (ortalama havuzlama) alarak işlem yapılır. Daha iyi performans gösterdiği için genellikle maksimum havuzlama tercih edilir.¹⁰⁸

c. Tam bağlantılı katman (Fully connected layer): Bu katman kendinden önceki katmanın tüm alanlarına bağlıdır ve mimarilere göre sayısı değişebilir.¹⁰²

f. DropOut katmanı: ESA'da ağı bazı düğümlerinin ortadan kaldırılmasıyla ezberlemesinin önüne geçmek için kullanılan katmandır.¹⁰⁵

g. Sınıflandırma katmanı (Classification layer): Sınıflandırma işleminin yapıldığı bu katmanın çıktı düğümü sayısı, sınıflandırılacak nesnelerin sayısına eşit olmaktadır.¹⁰²

h. Yumuşatma katmanı (Softmax layer): Sınıflandırma katmanı olarak yer alan softmax katmanı, tam bağlı katmandan girdi verisini alır ve sınıflandırmada

kullanır. İstenilen bir girdi verisinin belirli bir sınıfa ait olma durumunu ve hangi sınıfa daha yakın olduğunu belirlerken önemli bir rol oynar.¹⁰⁹

i. Normalizasyon katmanı (Normalization layer): ESA'ların eğitim süresinin azaltılmasında nöronların aktivasyonunu normalize etmek gerekir. Bu katman geri beslemeli ağlarda gizli katmanlardaki durumları stabil etmede yardımcıdır. Genellikle ReLu katmanından sonra normalleştirme gerçekleştirilir, normalizasyon ağın performansını olumlu yönde etkilemektedir.¹⁰⁹

ESA'nın eğitilmesi:¹⁰²

1. Öncelikle konvolüsyon, havuzlama, tam bağlantılı ve sınıflandırma katmanı belirlenen bir ESA modeli oluşturulur. Katmanların sayısı ve sıralaması tasarımcıya bağlıdır.

2. Filtre boyutları, sayısı ve adım kayma miktarı gibi başlangıç değişkenleri tanımlanır. Her filtre için 0-1 arasında rastgele değerler verilir.

3. Oluşturulan modelde girdi verisi olarak eğitim setinden bir görüntü verilir ve ağdaki katmanlardan geçerek bir sonuç değeri elde edilir. Bu aşamaya “ileri besleme” denir. Her katmanda filtre ağırlıkları ile görüntüdeki piksel değerleri çarpılıp, toplanır ve bir sonraki katmana aktarılır.

4. Ağın üretmiş olduğu sonuçlar ile hedef sonuçların farkı alınarak toplam hata değeri hesaplanır.

5. Hata değerinin bütün ağırlıklara dağıtılması gereklidir, bu işlem için geri besleme yapılır. Ağırlıkların güncellenmesiyle ağın çıkışındaki toplam hata değeri düşürülmeye çalışılır. Dolayısıyla sınıflandırma başarısının artırılması amaçlanmaktadır.

6. Eğitim kümesindeki bütün görüntüler için 3. ile 5. basamak tekrar edilir.

Derin öğrenme sistemlerinde tipik bir ağın görevi, belirli bir girdinin bir dizi kategoriden hangi kategoriye ait olduğuna karar vermede genellikle sınıflandırma sistemi olarak kullanılmasıdır. Derin öğrenme, yatay çizgiler veya resimsel yapının temel düzeyinden daha karmaşık öğelerine kadar nesnelere cevap verebilecek ara temsilleri kendi kendine oluşturma yeteneğine sahiptir.¹⁰⁴ Derin

öğrenmenin kilit yönü, tanımlanan özellik katmanlarının insanlar tarafından tasarlanmayıp, ağın veri üzerindeki içsel yapıları kendiliğinden keşfetmesine dayanır.⁸³

Derin öğrenmenin günümüzde yaygın olarak kullanılmasının başlıca nedeni, yeterli sayıda veriye erişim imkanının olmasıdır. Modelleri eğiten algoritmaların ihtiyaç duydukları kaynakların temelini oluşturan verilere, dijitalleşmenin artmasıyla birlikte daha fazla sayıda erişim sağlanmaktadır. Yapılan işlemler bilgisayarlarda daha çok kaydedilmektedir ve daha çok ağa bağlanılmaktadır. Bu yüzden, eldeki kayıtların merkezileştirilmesi ve makine öğrenimi için uygun veri kümesi oluşturulması gereklidir. Son yıllarda, artan bu veri hacmi “Büyük Veri (Big Data)” alanını oluşturmuştur ve makine öğrenimi işlemlerini çok daha kolay hale getirmiştir. Derin öğrenmenin günümüzde kullanılmasının diğer bir nedeni, daha büyük modelleri çalıştırmak için hesaplama kaynaklarının yeterli olmasıdır. Yapay sinir ağlarında gizli katman sayısının artmasıyla birlikte kullanılan bellek hafızası ve hesaplama için bilgi işlemci kapasitesi artar. Gizli katman sayısı ne kadar fazlaysa ağ o kadar derindir. Gizli katman sayısının artmasıyla daha büyük belleklere ve hızlı işlemcilere sahip bilgisayar ihtiyacı da artmaktadır.¹⁰²

LeNet, AlexNet, ZF Net, EfficientNet, DenseNet, VGGNet, GoogleNet, ResNet, R-CNN, Fast R-CNN ve Faster R-CNN gibi derin öğrenme algoritmaları vardır.^{83,102,110–113} Derin öğrenme ağlarının eğitimi için zaman ve depolama alanı gereklidir. ESA'nın katmanlarının derinliği ağın süresini, toplam parametre sayısı da depolama alanını etkilemektedir.¹¹⁴ Derin ağları geliştirmede verimliliği artırmak için Caffe, CTNK, TensorFlow, Torch, Theano, Keras gibi yazılım platformlarından son zamanlarda faydalanılmaktadır. Caffe, derin öğrenme ile görüntü işleme üzerine yazılan, önceden eğitilmiş modelleri olan ve Python, Matlab gibi uygulama dillerinde çalıştırılabilen bir kütüphanedir. TensorFlow, görüntü işlemede ve sayısal hesaplamalarda tercih edilen ve Google firması tarafından desteklenen açık kaynak kodlu bir kütüphanedir. Torch, Lua ve Python yazılım dilleri ile desteklenen, karmaşık problemleri basitleştirip, problem çözümünde algoritmayı hızlı ve esnek şekilde hazırlayan derin öğrenme kütüphanesidir. Theano, çok boyutlu dizileri içeren matematiksel ifadeleri verimli

bir şekilde tanımlamaya, optimize etmeye ve değerlendirmeye olanak sağlayan bir Python kütüphanesidir. Keras, Python programlama dili üzerine yazılmış ve TensorFlow üzerinde de çalışan yüksek seviyeli ve kullanımı kolay bir derin öğrenme kütüphanesidir.^{115,116}

2.8. Diş Hekimliğinde Yapay Zekâ Uygulamaları

Günümüzde diş hekimliği alanında YZ sistemine dayalı sanal asistanlar bulunmaktadır. Sanal asistanlar yapılacak işleri daha az insan gücü kullanarak, daha hassas şekilde ve daha az hata ile yapmaktadır. Hastaların randevularını düzenleme, hastaları diş hekimi kontrolüne gitmesi konusunda uyarma, evrak işleri ve sigortayı yönetme, hastanın herhangi bir maddeye karşı alerjisi varsa diş hekimine hatırlatma gibi görevleri vardır.¹¹⁷

YSA, özellikle hastalık etiyolojisinin çok faktör içerdiği durumlarda tanı koymada iyi performans göstermektedir. Karmaşık ağız hastalıklarının teşhisinde, oral prekanserlerin veya oral kanser gelişme riski taşıyan hastanın tanımlanmasında, temporomandibular eklem içindeki düzensizliklerin tanısının konulması gibi durumlarda yüksek özgüllük ve duyarlılığa sahip olması ve hekim hata olasılığını azaltması nedeniyle klinik uygulamalarda kullanılmaktadır.^{117,118}

YZ, manyetik rezonans görüntüleme, BT ve KIBT gibi görüntü sistemlerine entegre edilerek insan gözünün fark edemediği normalden çok küçük sapmaları tespit edebilir.^{117,118} YSA, hekimlerin proksimal çürükleri teşhis etmesine yardımcı olabilir.^{119,120}

YZ, ortodonti alanında tanı, tedavi planlaması ve takip olmak üzere ortodontik tedavinin çeşitli aşamalarında kullanılmaktadır. Üç boyutlu tarayıcılar ve sanal modeller özellikle kraniyofasiyal ve dental anomalilerin değerlendirilmesinde yardımcı olmaktadır.^{117,118}

Protezin kenar uyumu ve tutuculuğunda bilgisayar destekli teknolojilerin kullanımı YZ'nın diş hekimliği alanındaki bir başka gelişimidir. Yapılan diş tedavisinin sonucunu tahmin etmeye ve implantoloji veya herhangi bir cerrahi işlemde operasyondan önce detaylı planlama yapmaya yardımcı olur.^{117,118}

Dental implantlara alternatif değerlendirme metodu olarak kayıp dişlerin boyutlarının tahmini için yapılan bir çalışmada yapay sinir ağlarının implantların boy ve genişlikleri için tahmin imkânı verebileceği sonucuna varılmıştır.¹²¹

YZ'nın en büyük gelişmelerinden biri olan robotlar diş hekimliğinde pek çok alanda kullanılmaya başlanmıştır. Uzun saatler süren çalışmalardan sonra zihinsel ve fiziksel olarak yorulan ve ergonomik çalışma ortamı olmayan diş hekimleri hasta muayenesinde, yanlış hastalık teşhisi veya tedavi planlamasına ve işlem hatalarına neden olabilir. Literatürde robotların, diş hekimliği eğitiminde pratik becerileri geliştirmek ve eğitim sürecini desteklemek, diş hekimlerine yardımcı sanal asistan olarak, otonom implant yerleştirme veya diş preparasyonu gibi invaziv işlemlerde kullanıldığı bildirilmiştir.^{117,122}

2.9. Diş Hekimliğinde Derin Öğrenme

Tıp ve diş hekimliği alanında, ikinci görüş elde etmek için bilgisayar destekli tanı yazılımı kullanılmıştır. Son zamanlarda, tıp ve diş hekimliği uygulamalarında tasarımı ve ayarlanması zor olan geleneksel bilgisayar destekli tanı yazılımı sistemine derin öğrenme tekniklerinin entegre edilmesi yaygınlaşmıştır. Diş hekimliğinde derin öğrenmenin niteliksel ve niceliksel uygulamalarının genişlemesi teşhis ve tedavi süreçlerinde daha doğru ve etkili kararlar alınmasını sağlamıştır.^{123,124}

Derin ESA kullanılarak hem iki boyutlu (periapikal, bitewing, panoramik) hem de üç boyutlu (KIBT) görüntüler üzerinde yapılan araştırmalarda dişleri otomatik tanıma ve sınıflandırma, diş yüzeylerindeki çürükleri tespit etme, periapikal görüntülerdeki lezyonların teşhisi, periodontal kemik rezorpsiyonunun tespiti ve miktarı, ağız içi anatomik yapıların incelenmesi, osteoporoz tanısı, görüntü segmentasyonu, hastalığın seyrinin tahmin edilmesi, kist veya tümör tespit ve teşhisinde, ortodontik analizler gibi durumlarda kullanılmıştır. Ayrıca, ağız kokusunun tespitinde ve oral mukoza patolojilerinin tanımlanmasında da derin öğrenme tabanlı görüntü analizlerinden yararlanılmıştır.^{123,124}

Kök kanal tedavisinin başarısında önemli yere sahip olan mandibular ikinci molar dişlerdeki C şekilli kanal formasyonunun panoramik radyografi üzerinde tespitinde yine derin öğrenme mimarileri kullanılmıştır.¹²⁵⁻¹²⁷ Panoramik

radıyografilerde mandibular ikinci molar dişlerdeki C şeklindeki kanalları tahmin etmek için Xception konvolüsyonel sinir ağı (CNN) sisteminin kullanıldığı bir çalışmada, CNN modelinin tanısal performansını diş hekimliği uzmanları tarafından konulan tanıyla karşılaştırmak için doğruluk, duyarlılık, özgüllük, kesinlik değerleri hesaplanmıştır. CNN modelinin, C şeklindeki kanalları tahmin etmede diş hekimliği uzmanlarından daha iyi performans sergilediği bulunmuştur.¹²⁵

Kök kanal tedavisinin başarısında önemli yere sahip olan mandibular ikinci molar dişlerdeki C şekilli kanal formasyonunun KIBT üzerinde tespitinde ve sınıflandırılmasında yine derin öğrenme mimarisi kullanılmıştır. KIBT görüntüleri üzerinde evrişimli sinir ağlarına (CNN'ler) dayalı U-Net, rezidüel U-Net ve Xception U-Net mimarileri, mandibular ikinci azı dişlerindeki C şekilli anatomilerin görüntü segmentasyonu ve sınıflandırılması için kullanılmıştır. Bu çalışmanın bulguları, derin öğrenmenin KIBT görüntülerinde otomatik olarak C şekilli kanal anatomisini sınıflandırma potansiyeline sahip olduğunu göstermiştir ve bu derin öğrenme mimarilerinin performansları değerlendirilmiştir.¹²⁸

Derin öğrenme mimarilerinin kullanılarak yapıldığı bazı araştırmalar tablo 2.2’de verilmiştir.

Tablo 2.2. Derin öğrenme yöntemini kullanan bazı araştırmalar

Konu	Görüntüleme Yöntemi	Araştırma	Derin Öğrenme Mimarileri
Diş Tanıma-Sınıflandırma	KIBT	Miki ve ark. 2017	AlexNet
		Zhang ve ark. 2018b	ESA
	Periapikal Radyografi	Chen ve ark. 2019	Inception ResNetV2
		Görürgöz ve ark. 2021	GoogleNet InceptionV3
	Panoramik Radyografi	Tuzoff ve ark. 2019	VGG16
		Bilgir ve ark.2021	R-ESA InceptionV2
	Üç Boyutlu Dental Modeller	Xu ve ark. 2018	ESA
		Tian ve ark. 2019	ESA
Diş Eksikliği Tespiti	Panoramik Radyografi	Çelik ve ark. 2019	Google Net InceptionV3
Diş Morfolojisi	Panoramik Radyografi BT	Hiraiwa ve ark. 2019	AlexNet GoogleNet
		De Tobel ve ark. 2017	AlexNet
Üçüncü Molar Dişler	Panoramik Radyografi	Vranckx ve ark. 2020	ESA
		Kim ve ark. 2021	ResNet18
		Sukegawa ve ark. 2021	VGG16
		Vinayahalingam ve ark. 2021	MobileNetV2

Tablo 2.2. ‘Devam’

Çürük Teşhisi	Periapikal Radyografi	Lee ve ark. 2018a	GoogleNet
		Khan ve ark. 2021a	InceptionV3
	Bitewing Radyografi		U-Net
		Cantu ve ark. 2020	U-Net
Periapikal Radyolusensi	Kızılötesi Transillüminasyon	Casalegno ve ark. 2019	ESA
		Schwendicke ve ark.2020	Resnet18/ResNet50
	Panoramik Radyografi	Endres ve ark. 2020	U-Net
		Khan ve ark. 2021b	U-Net
Periapikal Lezyon Teşhisi	Panoramik Radyografi	Ekert ve ark. 2019	ESA
	KIBT	Setzer ve ark. 2020	U-Net
		Orhan ve ark. 2020	U-Net
	Periapikal Radyografi	Pauwels ve ark. 2020	ESA
Periodontal Kemik Kaybı	Panoramik Radyografi	Kim ve ark. 2019a	ESA
		Krois ve ark. 2019	ESA
		Bayrakdar ve ark. 2020	Google Net InceptionV3
		Chang ve ark. 2020	ESA
Anatomik Yapıların İncelenmesi	Periapikal Radyografi	Khan ve ark. 2021c	U-Net
	Panoramik Radyografi	Vinayahalingam ve ark. 2019	ESA
		Fukuda ve ark. 2020	VGG16/AlexNet/GoogleNet
	KIBT	Kwak ve ark. 2020	U-Net
		Orhan ve ark. 2021	ESA

Tablo 2.2. ‘Devam’

C Şekilli Kanal Tespiti	Panoramik Radyografi	Sujin Yang ve ark.	EfficientNet
	KIBT	Adithya A.Sherwood	U-Net
Osteoporoz Tanısı	Panoramik Radyografi	Lee ve ark. 2019a	AlexNet
Ortodontik Analizler	Lateral Sefalometri	Park ve ark. 2019	ESA
Çene Kistleri	Panoramik Radyografi	Poedjiastoeti ve Suebnukarn 2018	VGG16
	Ultrasonografi	Lee ve ark. 2018b	GAP
	KIBT	Ariji ve ark. 2019	AlexNet
	KIBT	Lee ve ark. 2020	GoogleNet
	Panoramik radyografi	Lee ve ark. 2019b	VGG16/VGG19/Xception/DenseNet169/InceptionResNetV2/DenseNet121
Servikal Lenf Nodu Metastazı	BT	Tomita ve ark. 2021	Xception
		Sukegawa ve ark. 2020	VGG16/VGG19
	Panoramik Radyografi	Takahashi ve ark. 2020	Yolow3
	Periapikal Radyografi	Kim ve ark. 2020	D-ESA
Ağız Kokusu Tespiti		Nakano ve ark. 2018	YSA
Oral Kanser Teşhisi	Akıllı Telefonla Çekilmiş Fotoğraflar	Uthoff ve ark. 2018	ESA
	Raman Spektroskopisi	Yu ve ark. 2019	ESA

Çalışmamızın amacı 37 ve 47 numaralı dişlerde kron ve kök (kron-kök) ve sadece kök veri setimiz kendi içinde orijinal görüntüler ve veri ön işleme yapılan görüntüler olarak iki alt gruba ayrılarak derin öğrenme mimarileri ile C şekilli kanal formasyonunun tespitinin ortalama doğruluk değerlerinin tespit edilmesi amaçlanmıştır ve bu gruplarda derin öğrenme mimarilerinin çeşitli kombinasyonları ile en yüksek doğruluk değerine ulaşmaya çalışılmıştır. Ayrıca kron-kök ve sadece kök veri setlerinin orijinal ve ön işleme yapılan görüntülerinden elde edilen bu doğruluk değerlerinin bütün kombinasyonları denenip çoğunluk oylaması (majority voting) yapılarak en yüksek doğruluk değerlerine ulaşılması amaçlanmıştır. İstatiksel analiz verileriyle YZ algoritmalarının doğruluk değerlerinin kron-kök ve kök grubunun tüm görüntü verisinde birbiriyle uyumu, yapay zekâ algoritmalarının doğruluk değerlerinin kron-kök ve sadece kök veri setlerinin orijinal ve ön işleme yapılan görüntü gruplarında aralarında anlamlı bir farklılık olup olmadığı ve YZ algoritmalarının doğruluk değerlerinin kron-kök ve sadece kök veri setlerinin orijinal ve ön işlem yapılmış görüntü verileri arasında anlamlı bir farklılık olup olmadığı değerlendirilmeye çalışılmıştır.

3. GEREÇ VE YÖNTEM

3.1. Görüntü Veri Setlerinin Oluşturulması


3.1.1. Hasta Seçimi ve Görüntü Veri Kümesinin Oluşturulması

Bu çalışmaya 1 Ocak 2019-1 Mart 2022 tarihleri arasında Pamukkale Üniversitesi, Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalına başvuran hastalardan çeşitli nedenlerle alınan hem dijital panoramik radyografisi hem de KIBT görüntüleri bulunan ve yaşları 18-65 arasında değişen 592 hastaya ait görüntüler dahil edildi. Dahil edilen radyografilerde gelişimini tamamlamış ve herhangi bir tedavi uygulanmamış (kök dolgusu, post veya kron restorasyonu olmayan) 37 veya 47 numaralı dişlerinden en az birisinin bulunmasına dikkat edildi. Derin çürüklü, kök rezorpsiyonu olan, pulpal kalsifikasyonlu ve açık apeksli 37 ve 47 nolu dişler çalışma dışı bırakıldı. 18 ila 65 yaşları arasındaki çalışmaya dahil edilme kriterlerini karşılayan tüm hastalar çalışmaya dahil edilmiş olup, çalışmaya dahil edilen tüm hastaların dijital panoramik radyografileri YZ algoritmaları kullanılarak retrospektif olarak değerlendirildi. Ağız, Diş ve Çene Radyolojisi bölümüne başvuran hastaların çeşitli nedenlerle alınan KIBT (Newtom 5G XL Cefla, Imola, İtalya 110 kVp, 3.00-8.73 mA, 3.6-5.4 sn tarama süresi ve voksel boyutu 0.125-0.250 mm) görüntüleri incelendi. C şekilli bir kanalın varlığını doğrulamak için KIBT görüntüleri analiz edildi ve altın standart olarak kabul edildi. Aynı hastaların fakültemizde çekilmiş panoramik filmleri windows bitmap (.bmp) formatında indirilip, panoramik görüntülerinden alınan kayıtlar YZ uygulamasıyla etiketlendi. Metal artefaktı, çekim sırasında hasta pozisyonundan kaynaklı artefaktlar, hareket artefaktı vb. sebeplerden kaynaklı panoramik ve konik ışınli bilgisayarlı tomografi görüntüleri çalışmaya dahil edilmedi. Panoramik radyografiler, (OP200D; Instrumentarium Şirketi, Görüntüleme Birimi, Tuusula, Finlandiya, 66 kVp 2,5 mA 13,4 sn ve 60 kVp, 6,3 mA 14,1 sn) aralığındaki pozlama değerleri ile elde edildi. Çalışmada öncelikli olarak panoramik radyograflar YZ algoritmaları kullanılarak retrospektif olarak değerlendirildi.

Çalışma protokolü Pamukkale Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu tarafından onaylanmıştır (E60116787-020-353313) (Ek-1). Çalışma, Helsinki Bildirgesi İlkelerine göre yapılmıştır.

Hasta isimleriyle isimlendirilip indirilen görüntü veri setimiz excel içerisinde C şekli var/yok bilgisine göre yeniden isimlendirildi ve txt dosyaları oluşturuldu. Her görüntü üzerinde kaç adet veri olduğu text dosyası içerisine kaydedildi (Şekil 3.1.1 ve Şekil 3.1.2).

Çalışmaya C şekilli kanal bulunan 289 ve C şekilli olmayan 303 panoramik radyografi dahil edildi. C şekilli kanal bulunan 289 panoramik radyografiden tek taraflı ve çift taraflı olmak üzere 422 C şekilli kanal bulunan 37 ve 47 numaralı dişler ve C şekilli kanal bulunmayan 303 panoramik radyografiden C şekilli kanal sayısı aynı olacak şekilde 422 C şekilli kanal bulunmayan 37 ve 47 numaralı dişler panoramik radyografide etiketlendi. Böylece C şekilli kanal bulunan ve bulunmayan 844 adetlik görüntü veri setimiz oluşturuldu.



Ad	Boyut	Sık. Boyut	Tür	Değişme	CRC32
001_37_c_47_c_2...	4,205,800	4,206,055	PNG Dosyası	8.03.2023 18:43	C334928C
002_37_c_47_c_2...	683,457	669,621	PNG Dosyası	4.07.2023 21:02	F79D5A12
003_37_c_47_c_2...	848,550	838,015	PNG Dosyası	5.03.2023 15:18	F7D5A628
004_37_c_1.png	615,502	599,201	PNG Dosyası	22.07.2023 16:41	54C7C637
005_37_c_47_c_2...	4,139,174	4,140,005	PNG Dosyası	8.03.2023 17:27	9CAB37D7
006_37_c_47_c_2...	4,043,505	4,044,203	PNG Dosyası	8.03.2023 18:51	6F6B5A5A
007_37_c_47_c_2...	624,548	609,991	PNG Dosyası	19.07.2023 21:10	A0DCA8B7
008_37_c_47_c_2...	844,823	833,246	PNG Dosyası	5.03.2023 19:28	14121922
009_37_c_47_c_2...	4,672,913	4,673,034	PNG Dosyası	4.03.2023 15:00	E5D0DE62
010_37_c_47_c_2...	4,247,330	4,247,873	PNG Dosyası	8.03.2023 17:39	715918A9
011_37_c_47_c_2...	844,994	833,119	PNG Dosyası	7.03.2023 15:28	2033D25F
012_37_c_47_c_2...	4,295,282	4,296,037	PNG Dosyası	8.03.2023 17:51	5364107D
013_37_c_47_c_2...	846,210	835,555	PNG Dosyası	4.07.2023 20:46	C8F8782D
014_37_c_47_c_2...	4,204,075	4,204,536	PNG Dosyası	19.07.2023 21:14	F2822389
015_37_c_47_c_2...	592,855	577,316	PNG Dosyası	4.07.2023 21:06	60C27828
016_37_c_1.png	4,459,016	4,468,480	PNG Dosyası	7.03.2023 19:37	4B4E1E17
017_37_c_1.png	895,169	883,582	PNG Dosyası	8.03.2023 18:42	89C56B21
018_37_c_47_c_2...	4,336,269	4,336,276	PNG Dosyası	8.03.2023 16:26	532C779C
019_37_c_47_c_2...	845,435	834,633	PNG Dosyası	5.03.2023 17:07	E23908F9
020_37_c_47_c_2...	4,247,235	4,247,272	PNG Dosyası	5.03.2023 18:19	148D38A2
021_37_c_47_c_2...	818,727	807,541	PNG Dosyası	4.07.2023 21:12	1048E125
022_37_c_47_c_2...	571,963	557,550	PNG Dosyası	19.07.2023 20:59	705FDCB7
023_37_c_47_c_2...	4,285,529	4,286,369	PNG Dosyası	8.03.2023 17:41	812F735D
024_37_c_1.png	4,211,160	4,211,783	PNG Dosyası	8.03.2023 17:19	D3D08B90
025_37_c_47_c_2...	857,622	845,459	PNG Dosyası	5.03.2023 15:43	B4C0C8B1
026_37_c_47_c_2...	4,195,548	4,195,777	PNG Dosyası	15.06.2023 21:04	777321DC
027_37_c_47_c_2...	4,381,653	4,381,395	PNG Dosyası	8.03.2023 18:42	14C2C8DA
028_37_c_47_c_2...	838,406	847,454	PNG Dosyası	5.03.2023 15:35	BACBEC7
029_37_c_47_c_2...	4,160,604	4,160,895	PNG Dosyası	5.03.2023 15:08	2150895F
030_37_c_47_c_2...	4,326,375	4,307,533	PNG Dosyası	5.03.2023 14:58	8C74E864
031_37_c_47_c_2...	878,365	867,591	PNG Dosyası	5.03.2023 18:27	A066F995
032_37_c_47_c_2...	4,215,992	4,218,073	PNG Dosyası	5.03.2023 14:59	4AD2B524
033_37_c_47_c_2...	818,440	800,045	PNG Dosyası	3.08.2023 15:45	54513E18

Toplam 289 dosya, 821,250,825 byte.

Şekil 3.1.1. Veri setindeki C şekilli görüntülerin isimlendirilme örneği


Adı	Boyut	Size boyutu	Tür	Değiştirme	Özellikler
210_37_msk_47_...	4.212.240	4.212.240	PNG Dosyası	2.10.2023 11:06	50442507
211_37_msk_47_...	826.449	815.489	PNG Dosyası	2.10.2023 11:06	8163128D
212_37_msk_47_...	4.247.550	4.247.545	PNG Dosyası	2.10.2023 11:06	D53878B5
213_37_msk_47_...	4.073.166	4.071.166	PNG Dosyası	2.10.2023 11:06	958852M4
214_37_msk_47_...	863.816	849.819	PNG Dosyası	2.10.2023 11:06	81189C06
215_37_msk_47_...	4.234.131	4.235.033	PNG Dosyası	2.10.2023 11:06	F488D578
216_37_msk_47_...	875.363	864.704	PNG Dosyası	2.10.2023 11:06	4717A3DC
217_37_msk_47_...	4.325.768	4.326.319	PNG Dosyası	2.10.2023 11:06	2D4F1478
218_37_msk_47_...	4.423.122	4.422.988	PNG Dosyası	2.10.2023 11:06	94A458ED
219_37_msk_47_...	863.601	851.839	PNG Dosyası	2.10.2023 11:06	53705678
220_37_msk_47_...	4.276.322	4.276.294	PNG Dosyası	2.10.2023 11:06	EC2047A7
221_37_msk_47_...	853.825	851.544	PNG Dosyası	2.10.2023 11:06	707F6490
222_37_msk_47_...	4.120.118	4.119.274	PNG Dosyası	2.10.2023 11:06	48F9F26F
223_37_msk_47_...	4.074.880	4.075.089	PNG Dosyası	2.10.2023 11:06	765650E8
224_37_msk_47_...	632.940	619.044	PNG Dosyası	2.10.2023 11:06	12563A1D
225_37_msk_47_...	875.855	865.754	PNG Dosyası	2.10.2023 11:06	3F882443
226_37_msk_47_...	4.362.769	4.363.407	PNG Dosyası	2.10.2023 11:06	D0C23652
227_37_msk_47_...	598.731	584.383	PNG Dosyası	2.10.2023 11:06	2C85D0C0
228_37_msk_47_...	4.282.448	4.282.879	PNG Dosyası	2.10.2023 11:06	87C80E51
229_37_msk_47_...	4.117.767	4.117.152	PNG Dosyası	2.10.2023 11:06	8C762055
230_37_msk_47_...	861.782	850.139	PNG Dosyası	2.10.2023 11:06	28A41A66
231_37_msk_47_...	4.247.211	4.247.504	PNG Dosyası	2.10.2023 11:06	A636C392
232_37_msk_47_...	587.070	572.188	PNG Dosyası	2.10.2023 11:06	8E2C47E3
233_37_msk_47_...	568.138	553.819	PNG Dosyası	2.10.2023 11:06	43F38629
234_37_msk_47_...	1.407.081	1.406.881	PNG Dosyası	2.10.2023 11:06	7D7C0FED
235_37_msk_47_...	625.459	611.779	PNG Dosyası	2.10.2023 11:06	99542B30
236_37_msk_47_...	4.158.442	4.156.487	PNG Dosyası	2.10.2023 11:06	7D7F6D77
237_37_msk_47_...	879.482	866.475	PNG Dosyası	2.10.2023 11:06	C8ED7C23
238_37_msk_47_...	609.183	594.447	PNG Dosyası	2.10.2023 11:06	8B462C59
239_37_msk_47_...	624.780	611.287	PNG Dosyası	2.10.2023 11:06	DE066287
240_37_msk_47_...	595.168	581.535	PNG Dosyası	2.10.2023 11:06	F0C0C649
241_37_msk_47_...	4.385.452	4.386.381	PNG Dosyası	2.10.2023 11:06	E55C9405
242_37_msk_47_...	4.337.038	4.336.303	PNG Dosyası	2.10.2023 11:06	8D2A1C8A

Şekil 3.1.2. Veri setindeki C şekilsiz görüntülerin isimlendirilme örneği


3.1.2. Görüntü Verilerinin Ön İşleme Süreçlerinden Geçirilmesi

Veri setindeki görüntüler üzerinde CLAHE (Kontrastla Sınırlı Uyarlanabilir Histogram Eşitleme) algoritması kullanılarak kontrast iyileştirme yapıldı. Ayrıca görüntü üzerindeki gürültüyü azaltmak, kenarları korumak ve aynı zamanda görüntüyü yumuşatmak için bilateral filtreleme tekniği görüntüler üzerinde kullanıldı. Böylece hem kron ve kök (kron-kök) hem de kök veri grubumuzdaki C kanallı ve kanalsız bütün orijinal görüntü verilerimize veri ön işleme yapılarak (CHALE ve Bilateral Filtreleme) ön işlem yapılmış görüntülerimiz elde edildi (Şekil 3.3, Şekil 3.4, Şekil 3.5 ve Şekil 3.6).


Orijinal ve ön işlemlili görüntülerin (flipli ve flipsiz) derin öğrenme algoritmalarıyla doğruluk değerleri ve majority voting (füzyon) doğruluk değerleri hem kron-kök hem de kök görüntülerde tespit edildi. Bu işlemler sayesinde derin öğrenme algoritması sonucu elde edilecek başarı artırıldı.




Şekil 3.2. C şekilli kanal görüntülerine uygulanan veri ön işleme bilateral filtreleme. A. Orijinal Görüntü, B. CLAHE Görüntü, C. CLAHE Görüntü, D. Bilateral Filtrenilmiş Görüntü



Şekil 3.3. C şekilli kanala sahip olmayan görüntülere veri ön işleme bilateral filtreleme. A. Orijinal Görüntü, B. CLAHE Görüntü, C. CLAHE Görüntü, D. Bilateral Filtrenilmiş Görüntü



Şekil 3.4. Sadece kök C şekilli kanal görüntülerine uygulanan veri ön işleme bilateral filtreleme. A. Orijinal Görüntü, B. CLAHE Görüntü, C. CLAHE Görüntü, D. Bilateral Filtrenilmiş Görüntü




Şekil 3.5. Sadece kök C şekilli kanala sahip olmayan görüntülere uygulanan veri ön işleme bilateral filtreleme. A. Orijinal Görüntü, B. CLAHE Görüntü, C. CLAHE Görüntü, D. Bilateral Filtrenilmiş Görüntü

3.1.3. Görüntü Verilerinin Kırılması


Manuel kırpmadan kaynaklı görüntü çözünürlük kaybının önüne geçmek için MATLAB R2021b versiyonlu kırpma programı ile veri setindeki her bir görüntü standart olmayan bir açı ile rotasyon yaptırılıp düzleştirilerek kırıldı. Kron-kök ve kök veri setindeki C şekilli ve C şekilli olmayan görüntü verileri MATLAB R2021b versiyonlu kırpma programı ile kırıldı (Şekil 3.6 ve Şekil 3.7), (Şekil 3.8 ve Şekil 3.9).




Şekil 3.6. C şekilli kanallı örnek görüntü verisinde tüm dişin MATLAB R2021b versiyonlu kırpma programı ile kırılması



Şekil 3.7. C şekilli kanallı örnek görüntü verisinde sadece kök kısmının MATLAB R2021b versiyonlu kırpma programı ile kırılması



Şekil 3.8. C şekilli kanalsız örnek görüntü verisinde tüm dişin MATLAB R2021b versiyonlu kırpma programı ile kırılması



Şekil 3.9. C şekilli kanalsız örnek görüntü verisinde sadece kök kısmının MATLAB R2021b versiyonlu kırpma programı ile kırılması

3.2. Derin Öğrenme Modellerinin Eğitilmesi ve Çalışmanın Genel Akış Diyagramı

Bu tez çalışması, Tensorflow kütüphanesi ile Python açık kaynaklı kodlama dili kullanan, ResNet50, ResNet50V2, VGG16, VGG19, EfficientNetB0, EfficientNetB1, InceptionV3, Xception, DenseNet169, DenseNet201 ve ResNet152V2 derin öğrenme algoritmaları kullanılarak yapıldı.

Modellerin eğitimi Ubuntu18.04.6 LTS (GNU/Linux 5.4.0-150-generic x86_64) işletim sistemine, AMD EPYC 7H12 64-Core Processor işlemciye, 62 GB Memory RAM'e, 1 adet NVIDIA Tesla A40 48 GB GPU ekran kartına sahip bir bilgisayarda gerçekleştirildi.

Tez çalışması kapsamında panoramik radyografiler üzerinde YZ algoritmaları retrospektif olarak değerlendirmek için oluşturulan derin sinir ağı modellerinin eğitim ve test aşamalarındaki genel iş akışı özetle aşağıdaki gibidir:

- Verilerin toplanması, eğitim, test ve doğrulama verilerinin belirlenmesi
- Verilerin ön işleme süreçlerinden geçirilmesi
- Verilerin yüklenmesi ve MATLAB R2021b versiyonlu kırpma programı ile kırılması
- Derin öğrenme modellerinin seçimi ve model hiper parametrelerinin tanımlanması
- Hiperparametreler ve programlama adımları ile derin sinir ağı modellerinin kurulması
- Eğitim verisi üzerinde modellerin eğitilmesi
- Doğruluk ve hata sonuçlarının alınarak modellerin değerlendirilmesi
- Eğitim ve test hata grafiklerinin yorumlanması, modellerin iyileştirilmesi ve tahmin sonuçlarının alınması.

Kron-kök ve kök veri setlerinin orijinal ve ön işleme yapılan görüntülerinden derin öğrenme algoritmalarıyla elde edilen doğruluk değerlerinin bütün kombinasyonları denenip çoğunluk oylaması (majority voting) yapılarak kron-kök ve kök veri setleri için en yüksek doğruluk değerlerine ulaşılmaya çalışıldı. Çoğunluk oylamasında eğitim tamamlandıktan sonra, her bir model kullanılarak test verileri üzerinde tahminler yapıldı. Her model, belirli bir sınıf etiketi için oy kullandı ve en çok oyu alan sınıf, nihai tahmin olarak seçildi. Tahmin sonucuna göre de doğruluk değeri hesaplandı.


844 veri setimiz hem kron ve kökün tamamını içine alacak şekilde hem de sadece kök kısmını içine alacak şekilde ayrı ayrı etiketlendi ve kırıldı. Çalışma için üç ayrı veri seti oluşturuldu; modelin eğitilmesi için *eğitim veri seti*, eğitim sürecinde modelin oluşturulup parametrelerin ayarlanması için *doğrulama veri seti*, eğitim ve doğrulama setleri aracılığı ile eğitilmiş modelin test edilebilmesi

için de *test veri seti* kullanıldı. Eğitim ve doğrulama veri seti tüm görüntülerin %90'ını oluşturan 760 panoramik radyografi görüntüsünden, test veri seti tüm görüntülerin %10'unu oluşturan 84 panoramik radyografi görüntüsünden oluştu. Eğitim ve doğrulama veri seti de kendi içinde yaklaşık %90'ını oluşturan 676 eğitim veri setinden ve %10'unu oluşturan 84 doğrulama veri setinden oluştu. Sonuç olarak veri setinin yaklaşık olarak %10'u test, %10'u doğrulama, %80'i de eğitim veri seti olarak ayrıldı (Tablo 3.1).

Tablo 3.1. Veri seti dağılımı

Eğitim Veri Seti	676 Görüntü
Doğrulama Veri Seti	84 Görüntü
Test Veri Seti	84 Görüntü


Kırpılan kron-kök ve kök (C şekilli ve C şekilli olmayan) görüntülerin orijinal ve ön işlemlili bütün görüntülerine flipleme işlemi yapılarak yani 37 nolu dişler 47 nolu dişler gibi alınarak flipli ve normal şekilde flipsiz olarak derin öğrenme modelleriyle doğruluk değerleri ayrı ayrı hesaplandı ve doğruluk değeri yüksek olan derin öğrenme algoritmasının flipli ya da flipsiz şeklinin çoğunluk oylaması (majority voting) değerleri alınarak kron-kök ve kök veri setleri için en yüksek doğruluk değerlerine ulaşılmaya çalışıldı.



Şekil 3.10. Derin öğrenme mimarileri ile gerçekleştirilen C şekilli kanallı dış tespit modelinin gelişim aşamalarının diyagramı

Eğitim veri setlerindeki sapmaların üstesinden gelmek ve en düşük test hatalarıyla sonuçlanacak hiper parametreleri belirlemek için modeller üzerinde on katlı çapraz doğrulama uygulandı. Veri setleri rastgele on parçaya bölündü; sekizi eğitim seti, biri test seti ve biri doğrulama seti olarak kullanıldı. On katlı çapraz

doğrulama katının (Fold (F)) her birinden elde edilen teşhis performanslarının ortalamaları hesaplandı ve bu değerler, modelin genel öngörücü performansı olarak kabul edildi. Her modelin ortalama performans değeri bu şekilde hesaplandı.



Şekil 3.11. On katlı çapraz doğrulama modeli

Görüntü özelliklerinin çıkarılması aşamasında kullanılan derin öğrenme mimarileri:

- **ResNet50(flipsiz)**
- **ResNet50V2(flipsiz)**
- **VGG16(flipli)**
- **VGG19(flipsiz)**

- **EfficientNetB0 (flipsiz)**
- **EfficientNetB1 (flipsiz)**
- **InceptionV3(flipli)**
- **Xception (flipsiz)**
- **DenseNet169 (flipsiz)**
- **DenseNet201 (flipsiz)**
- **ResNet152V2 (flipsiz)**

ResNet mimarisi, kimlik haritalarını ve doğrusal olmayan çoklu katman problemini çözmek için önerilen bir mimaridir. Resnet mimarisi birkaç kalıntı bloklarından oluşur. Bu mimari, VGG16 benzeri 3x3 filtreler kullanır ve girişte 224x224 piksellik görüntü alır.¹²⁹

Google tarafından geliştirilen InceptionV3 mimarisi Derin Öğrenme Evrişimli Mimariler serisinin üçüncü sürümüdür. InceptionV3, görüntü sınıflandırma alanında kullanılan en gelişmiş mimarilerden biridir. Bu mimari, birden fazla farklı boyuttaki evrişimli filtreyi yeni bir filtrede birleştiren bir başlangıç modeli önermektedir. Bu tür bir tasarım eğitilecek parametre sayısını azaltır ve böylece hesaplama karmaşıklığını da azaltır. Son katmanda Softmax fonksiyonu bulunan InceptionV3 mimarisi toplamda 42 katmandan oluşur ve girişte 299x299 piksel boyutlarında görüntü alır.¹³⁰

Simonyan ve Zisseman tarafından önerilen VGG16 mimarisi, parametre sayısını kısararak eğitim zamanını azaltmak için tasarlanmıştır. Kendinden bir önceki en başarılı ESA mimarisi olan AlexNet'den farklı olarak 3x3'lük filtre kullanmıştır ve VGG16 mimarisinde arka arkaya iki veya üç evrişim katmanı bulunmaktadır. VGG16 mimarisinde toplam on üç evrişim katmanı ve beş ortalama/ havuzlama katmanı bulunmaktadır. VGG16 mimarisi ile benzer bir mimariye sahip olan VGG19 mimarisinde on dokuz tane katman bulunmaktadır.¹³¹

EfficientNet grubu B0-B7 arasında sekiz tane modelden oluşur ve model numarası büyüdükçe hesaplanan parametre sayısı çok fazla artmaz iken doğruluk

dikkat çekici şekilde artar. Derin öğrenme mimarilerinde amaç daha küçük modeller ile daha verimli yaklaşımlar ortaya koymaktır. EfficientNet modeli, diğer gelişmiş modellerden farklı olarak, modeli küçültmeye çalışırken derinlik, genişlik ve çözünürlük açısından ölçekleme yaparak daha verimli sonuçlar üretir.¹³²

Xception, 2017 yılında ortaya konan sınıflama modelidir. Model giriş akışı, orta akış ve çıkış akışı olarak üç modülden oluşmaktadır. Giriş modülü 3x3 çekirdek boyutuna sahip, evrişim katmanları ve maksimum havuzlama katmanlarını içermektedir. Orta akış modülü sekiz kez tekrarlanan evrişim katmanlarından oluşmaktadır. Çıkış akışı modülü ise iki evrişim katmanı, maksimum havuzlama, iki evrişim katmanı ve global havuzlama katmanlarından oluşmaktadır. Bu modelde kullanılan evrişim katmanlarının tamamı ayrılabilir evrişim katmanlarıdır. Ayrılabilir evrişim, tek bir evrişimin aynı çıktıyı üretmek için iki veya daha fazla evrişime bölünebildiği bir süreçtir. Tek bir süreç, aynı etkiyi elde etmek için iki veya daha fazla alt sürece bölünür. Bu katmanlar, geleneksel evrişim katmanlarına göre hesaplama gereksinimlerini azaltarak ağı sadeleştirmektedir.¹³³

Sinir ağları eğitilirken konvolüsyon ve alt örnekleme işlemleri nedeniyle özellik haritalarında azalma meydana gelmektedir. Aynı zamanda katmanlar arası geçişlerde görüntü özelliğinde kayıplar olmaktadır. Görüntü özellik bilgilerinin daha etkili kullanılması için Huang tarafından DenseNet sistemi geliştirilmiştir. Yapılan sistemde her bir katman diğer katmanlara ileri beslemeli bir şekilde bağlanmıştır. Bu sayede herhangi bir katmanda kendinden önceki bütün katmanlara ait özellik bilgisine erişilebilmektedir.¹³⁴

3.2.1. Derin Öğrenme Modelleri için Hiperparametre Ayarlamaları ve Seçimleri

Hiperparametreler ile ilgili bilinen en önemli zorluk veri setine ve problem ihtiyacına bağlı olarak değişmesidir. Hiperparametreler genel olarak iki kategoriye ayrılır. Birincisi model hiperparametreleridir. Bu parametreler, modelin yapısında yer alan değişkenlerdir. Aktivasyon fonksiyonları, dropout, gizli katmanların sayısı ve modele özel hiperparametreler bu kategoridedir. İkincisi iyileştirici (optimizer) hiperparametrelerdir. Modelin yapısından ziyade eğitim ve optimizasyon süreçlerinde yer alan değişkenlerdir. Bu kategori de öğrenme

katsayısı (learning rate), mini-batch boyutu ve tüm eğitim seti üzerindeki devir sayısını (epoch) içermektedir.¹³⁵

Aktivasyon Fonksiyonları

Bir sinir ağına doğrusal olmayan özellikler kazandıran aktivasyon fonksiyonlarının temel amacı, bir ağ içindeki düğümün girdi sinyalini bir çıktı sinyaline dönüştürmektir. Bir yapay sinir ağında $\mathbf{x}$ girdileri ve bu girdilerin ilişkili olduğu $\mathbf{w}$ ağırlıkları toplanır ve bu sonuca $\mathbf{f}(\mathbf{x})$ aktivasyon fonksiyonu uygulanarak ilgili katmanın çıktısı alınır ve bir sonraki katmana girdi olarak verilir.¹³⁵

Öğrenme Katsayısı

Öğrenme katsayısı değerinin iyi ayarlanmış olduğundan emin olunmalıdır. Çok katmanlı sinir ağları için öğrenme katsayısı değerleri 0-1 aralığında, 1'den küçük ve 0,000006'dan büyük alınmalıdır. Genellikle 0,01 öğrenme katsayısı değeri iyi bir başlangıç noktası sayılmaktadır. Bununla birlikte, eğitim hatasının davranışına bağlı olarak 0,001, 0,0001 ve 0,00001 gibi değerler de yaygın olarak kullanılmaktadır. Öğrenme katsayısının belirlenmesinde kesin bir kural ve kısıtlamanın olmamasıyla birlikte, en iyi öğrenme katsayısı genellikle en az hata üretendir. Bu nedenle, modelin eğitim sürecindeki davranışını izleyerek en iyi değere ulaşmak mümkündür.¹³⁵

Mini-batch Boyutu

Modelin eğitiminde kullanılan hesaplama kaynaklarını, eğitim hızını ve iterasyon sayısını etkileyen bir hiperparametredir. Mini-batch, tek seferde tüm verilerin eğitilmesi yerine veri setinin alt kümeleri üzerinde eğitim yapmak için kullanılan bir tekniktir. Batch eğitimi için her devir başlangıcında veriler rastgele karıştırılır ve eğitim verileri daha küçük mini-batch'lere ayrılır. Model, her bir mini-batch üzerinde ileri besleme işlemi gerçekleştirir ve hata değerini hesaplar. Daha sonra her bir mini-batch üzerinde geri yayılım kullanılarak gradyan hesaplamaları gerçekleştirilir ve ağırlıklar güncellenir.¹³⁵

Devir Sayısı

Kısaca devir (epoch) sayısı olarak isimlendirilen eğitim yinelemelerinin sayısındaki her bir devir, tüm veri setinin ileri ve geriye doğru tek bir geçiş adımınıdır. Fazla veri gerektirmeden oluşturulan modelin doğruluğunu arttırmak için

kullanılmaktadır. Devir sayısı istenilen değerden büyük olduğunda model aşırı öğrenme problemiyle ve istenilen değerden küçük olduğunda ise eksik öğrenme problemiyle karşı karşıya kalmaktadır.¹³⁵

Gizli Katmanların Sayısı

Bir modelin kapasitesi, farklı problem ve görevleri öğrenme yeteneği olarak ifade edilmektedir. Modelin kapasitesi değiştirilerek aşırı öğrenme ya da eksik öğrenme durumları kontrol edilir. Düşük kapasiteli modeller eğitim setini eksik öğrenirken, yüksek kapasiteli modeller eğitim setini aşırı öğrenerek ezberlemektedir. Gizli birimlerin sayısı bir modelin öğrenme kapasitesinin ölçülmesi için önemli bir parametredir.¹³⁵

Çalışmamızda test grubundan elde edilen veriler tekrar kullanılmamıştır. Derin öğrenme modellerinin eğitimi, 100 epoch ve 0,0001 öğrenme katsayısı değerlerinde gerçekleştirilmiştir.

3.3. Yapay Zekâ Performansının Değerlendirilmesi

3.3.1. Performans Değerlendirme Metrikleri

Karmaşıklık matrisi, ikili sınıflandırma görevlerinde gerçek değerler ile sınıflandırıcının tahmin ettiği değerleri gösteren, 2x2 boyutunda olan bir matristir. Sistemlerin performansı genellikle matristeki veriler kullanılarak değerlendirilmektedir. Bu çalışmada kullanılan modellerin sınıflandırma performansı karmaşıklık (hata) matrisi kullanılarak değerlendirildi.

Tablo 3.2. İki sınıflı bir sınıflandırıcının hata matrisi

		Tahmin Edilen Durum	
		Pozitif	Negatif
Gerçek Durum	Doğru	DP	DN
	Yanlış	YP	YN

Çalışmamızda oluşturulan veri setlerinin sınıflandırma performansını ölçmede; doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru kullanıldı.

Doğru pozitif (DP), modelin tahmini pozitif iken, gerçekte de doğru olan durumdur.

Yanlış negatif (YN), modelin tahmini negatif iken, gerçekte ise doğru olan durumdur.

Yanlış pozitif (YP), modelin tahmini pozitif iken, gerçekte ise yanlış olan durumdur.

Doğru negatif (DN), modelin tahmini negatif iken, gerçekte de yanlış olan durumdur.

Doğruluk (Accuracy), sınıflandırma problemlerinde doğru tahminlerin toplam veri kümesine olan oranıdır. Hesaplama formülü:

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+DN+YN}$$

Kesinlik (Precision), pozitif olarak tahmin ettiğimiz değerlerin gerçekte kaç adetinin doğru olduğunu gösterir. Hesaplama formülü:

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

Duyarlılık veya Hassasiyet, pozitif olarak tahmin etmemiz gereken işlemlerin ne kadarının pozitif olarak tahmin ettiğimizi gösteren metriktir. Kesinlik metriği, sınıflandırıcının performansını yanlış pozitifler ile ifade ederken, duyarlılık metriği, bu performansı yanlış negatifler ile ifade eder. Hesaplama formülü:

$$\text{Duyarlılık} = \frac{DP}{DP+YN}$$

F1 Skoru, kesinlik ve duyarlılık ölçütlerinin ağırlık ortalamaları ile hesaplanan değerdir.

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

Bu tez çalışmasında verilerin istatistiksel analizi için sınıf içi korelasyon katsayısı, Kruskal Wallis Testi ve Mann Whitney U Testi kullanılmıştır. Örneklem sayısını arttırmak için bütün fold (F) değerleri çalışmaya dahil edilmiştir. Verilerin istatistiksel analizi için SPSS (Version 25.0, Chicago, USA) programı kullanılmıştır.




4. BULGULAR

Çalışmamızda, C şekilli kanallı diş tespiti için 11 farklı derin öğrenme modelinin orijinal ve ön işleme yapılan panoramik görüntülerden 37 ve 47 numaralı dişlerde (kron-kök ve kök şeklinde iki ayrı grup olacak şekilde) C şekilli kanal tespit doğruluk performans başarıları araştırılmıştır. Her bir model için karmaşıklık matrisi kullanılarak doğruluk performansları değerlendirilmiş ve derin öğrenme mimariyle bütün kombinasyonlar denenerek her grup için en yüksek ortalama doğruluk değerine ulaşılmaya çalışılmıştır.

Kron-kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları tablo 4.1 ve şekil 4.1’de gösterilmiştir.

Tablo 4.1. Kron-kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları

Kfold=10	Orijinal										
	InceptionV3	EfficientNetB1	EfficientNetB0	VGG16	VGG19	ResNet50	ResNet50V2	Xception	DenseNet169	DenseNet201	ResNet152V2
F1	0,8571	0,8333	0,8452	0,8571	0,869	0,8571	0,8809	0,8095	0,8333	0,8809	0,8571
F2	0,869	0,8452	0,8214	0,869	0,9047	0,8928	0,8452	0,8333	0,869	0,9166	0,8928
F3	0,8705	0,847	0,847	0,8705	0,8941	0,8705	0,8705	0,8941	0,8823	0,8705	0,8823
F4	0,8588	0,8	0,847	0,8235	0,847	0,8352	0,847	0,8235	0,8352	0,847	0,8352
F5	0,8823	0,8117	0,8235	0,8235	0,8352	0,847	0,847	0,8352	0,847	0,8352	0,8235
F6	0,8235	0,8352	0,8235	0,8705	0,8588	0,847	0,8352	0,8117	0,8352	0,8588	0,847
F7	0,7976	0,8214	0,7619	0,7857	0,7857	0,8333	0,8095	0,8095	0,8333	0,8214	0,8095
F8	0,9047	0,8928	0,9047	0,869	0,9047	0,8928	0,9047	0,8452	0,9047	0,9047	0,9047
F9	0,9285	0,869	0,8571	0,8928	0,9285	0,9166	0,8928	0,869	0,8928	0,8928	0,869
F10	0,8214	0,8333	0,7857	0,8095	0,7619	0,8452	0,8214	0,7976	0,8214	0,8095	0,8333
Ort.	0,8613	0,8388	0,8317	0,8471	0,858	0,8637	0,8554	0,8328	0,8554	0,8637	0,8554




Şekil 4.1. Kron-kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması

Kron-kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan doğruluk performans verisi sonuçlarına göre en yüksek ortalama doğruluk değeri 0,8637 olarak ResNet50 derin öğrenme modeliyle, en düşük ortalama doğruluk değeri ise 0,8317 ile EfficientNetB0 derin öğrenme modeliyle bulunmuştur. InceptionV3 derin öğrenme modelinin doğruluk değeri 0,8613, EfficientNetB1 derin öğrenme modelinin doğruluk değeri 0,8388, VGG16 derin öğrenme modelinin doğruluk değeri 0,8471, VGG19 derin öğrenme modelinin doğruluk değeri 0,858, ResNet50V2 derin öğrenme modelinin doğruluk değeri 0,8554, Xception derin öğrenme modelinin doğruluk değeri 0,8328, DenseNet169 derin öğrenme modelinin doğruluk değeri 0,8554, DenseNet201 derin öğrenme modelinin doğruluk değeri 0,8637 ve ResNet152V2 derin öğrenme modelinin doğruluk değeri 0,8554'tür (Tablo 4.1 ve Şekil 4.1).

Kron-kök veri setindeki ön işlemlı görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları tablo 4.2 ve şekil 4.2’de gösterilmiştir.

Tablo 4.2. Kron-kök veri setindeki ön işlemlı görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları


Ön İşlemlı											
Kfold=10	InceptionV3	EfficientNetB1	EfficientNetB0	VGG16	VGG19	ResNet50	ResNet50V2	Xception	DenseNet169	DenseNet201	ResNet152V2
F1	0,8928	0,75	0,7857	0,8571	0,8571	0,8333	0,8095	0,8571	0,8333	0,8452	0,8333
F2	0,869	0,8214	0,869	0,869	0,8928	0,8928	0,869	0,9047	0,8809	0,8809	0,9047
F3	0,8588	0,8117	0,8352	0,8823	0,8823	0,8705	0,847	0,8941	0,9058	0,8823	0,8823
F4	0,8588	0,8235	0,8	0,8117	0,8352	0,7764	0,8352	0,8	0,8235	0,8235	0,8235
F5	0,8705	0,8117	0,8352	0,8	0,847	0,8823	0,847	0,8352	0,8235	0,847	0,8588
F6	0,8941	0,8	0,847	0,8705	0,8588	0,8235	0,8823	0,847	0,8705	0,8705	0,8352
F7	0,8214	0,7976	0,738	0,7619	0,8095	0,7261	0,7738	0,7738	0,7857	0,7857	0,8333
F8	0,8809	0,8571	0,869	0,869	0,9047	0,9523	0,9166	0,8571	0,9285	0,9285	0,9047
F9	0,9285	0,9166	0,9047	0,9166	0,9047	0,9523	0,9047	0,9285	0,8809	0,869	0,9523
F10	0,7857	0,8333	0,7976	0,8095	0,7976	0,8333	0,8333	0,7619	0,7976	0,7976	0,8214
Ort.	0,866	0,8222	0,8281	0,8447	0,8589	0,8542	0,8518	0,8459	0,853	0,853	0,8649



Şekil 4.2. Kron-kök veri setindeki ön işlemlı görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması

Kron-kök veri setindeki ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan doğruluk performans verisi sonuçlarına göre en yüksek ortalama doğruluk değeri 0,866 olarak InceptionV3 derin öğrenme modeliyle, en düşük ortalama doğruluk değeri ise 0,8222 ile EfficientNetB1 derin öğrenme modeliyle bulunmuştur. EfficientNetB0 derin öğrenme modelinin doğruluk değeri 0,8281, VGG16 derin öğrenme modelinin doğruluk değeri 0,8447, VGG19 derin öğrenme modelinin doğruluk değeri 0,8589, ResNet50 derin öğrenme modelinin doğruluk değeri 0,8542, ResNet50V2 derin öğrenme modelinin doğruluk değeri 0,8518, Xception derin öğrenme modelinin doğruluk değeri 0,8459, DenseNet169 derin öğrenme modelinin doğruluk değeri 0,853, DenseNet201 derin öğrenme modelinin doğruluk değeri 0,853 ve ResNet152V2 derin öğrenme modelinin doğruluk değeri 0,8649'dur (Tablo 4.2 ve Şekil 4.2).

Kron-kök veri setindeki orijinal ve ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçlarının karşılaştırması şekil 4.3'te gösterilmiştir.




Şekil 4.3. Kron-kök veri setindeki orijinal ve ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması

Şekil 4.3'te görüldüğü gibi VGG19 derin öğrenme modelinin orijinal ve ön işlemleri görüntüler üzerindeki ortalama doğruluk performans verileri arasında herhangi bir farklılık görülmemektedir. Bununla birlikte InceptionV3, Xception ve ResNet152V2 derin öğrenme modellerinin ön işlemleri görüntülerdeki ortalama doğruluk performanslarının orijinal görüntülerdeki performanslarından daha yüksek olduğu, buna karşın EfficientNetB1, EfficientNetB0, VGG16, ResNet50, ResNet50V2, DenseNet169 ve DenseNet201 derin öğrenme modellerinin ise orijinal görüntülerdeki ortalama doğruluk performans verilerinin daha yüksek olduğu görülmektedir (Şekil 4.3).

Kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları tablo 4.3 ve şekil 4.4'te gösterilmiştir.

Tablo 4.3. Kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları

Kfold=10	Orijinal										
	InceptionV3	EfficientNetB1	EfficientNetB0	VGG16	VGG19	ResNet50	ResNet50V2	Xception	DenseNet169	DenseNet201	ResNet152V2
F1	0,8095	0,7857	0,8095	0,8333	0,8333	0,8214	0,8214	0,8095	0,7976	0,8214	0,8333
F2	0,8571	0,8333	0,8333	0,8571	0,9047	0,8571	0,8571	0,8809	0,8928	0,8452	0,8571
F3	0,8705	0,8	0,8352	0,8235	0,8823	0,847	0,8705	0,8000	0,8941	0,8823	0,8352
F4	0,847	0,8588	0,8588	0,8352	0,8823	0,847	0,8823	0,8352	0,8705	0,8705	0,8705
F5	0,8352	0,8117	0,7647	0,8588	0,847	0,8705	0,8588	0,8117	0,847	0,8705	0,8352
F6	0,847	0,8235	0,847	0,8352	0,7882	0,8	0,8235	0,8117	0,8352	0,8117	0,7882
F7	0,8095	0,7976	0,8095	0,8095	0,8571	0,8214	0,8095	0,8333	0,8571	0,8571	0,8928
F8	0,8809	0,8809	0,869	0,8928	0,9047	0,9047	0,8214	0,8452	0,9047	0,8809	0,8571
F9	0,9285	0,8214	0,8571	0,869	0,8809	0,869	0,8809	0,869	0,9047	0,8809	0,8809
F10	0,8452	0,8214	0,7976	0,8928	0,8452	0,8809	0,869	0,8095	0,869	0,8928	0,869
Ort.	0,853	0,8234	0,8281	0,8507	0,8625	0,8519	0,8494	0,8306	0,8672	0,8613	0,8519




Şekil 4.4. Kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması

Kök veri setindeki orijinal görüntülerin derin öğrenme mimarileriyle bulunan doğruluk performans verisi sonuçlarına göre en yüksek ortalama doğruluk değeri 0,8672 olarak DenseNet169 derin öğrenme modeliyle, en düşük ortalama doğruluk değeri ise 0,8234 ile EfficientNetB1 derin öğrenme modeliyle bulunmuştur. InceptionV3 derin öğrenme modelinin doğruluk değeri 0,853, EfficientNetB0 derin öğrenme modelinin doğruluk değeri 0,8281, VGG16 derin öğrenme modelinin doğruluk değeri 0,8507, VGG19 derin öğrenme modelinin doğruluk değeri 0,8625, ResNet50 derin öğrenme modelinin doğruluk değeri 0,8519, ResNet50V2 derin öğrenme modelinin doğruluk değeri 0,8494, Xception derin öğrenme modelinin doğruluk değeri 0,8306, DenseNet201 derin öğrenme modelinin doğruluk değeri 0,8613 ve ResNet152V2 derin öğrenme modelinin doğruluk değeri 0,8519'dur (Tablo 4.3 ve Şekil 4.4).

Kök veri setindeki ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları tablo 4.4 ve şekil 4.5'te gösterilmiştir.

Tablo 4.4. Kök veri setindeki ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçları

Ön İşlemlili											
Kfold=10	InceptionV3	EfficientNetB1	EfficientNetB0	VGG16	VGG19	ResNet50	ResNet50V2	Xception	DenseNet169	DenseNet201	ResNet152V2
F1	0,8095	0,7857	0,75	0,7857	0,8214	0,8095	0,7976	0,7619	0,8214	0,7619	0,8214
F2	0,8571	0,8095	0,8571	0,8928	0,9047	0,8928	0,8809	0,8928	0,8928	0,9047	0,8809
F3	0,8941	0,8117	0,8352	0,8705	0,8705	0,8588	0,847	0,8117	0,8705	0,9176	0,8705
F4	0,847	0,8	0,8588	0,8235	0,847	0,8352	0,8705	0,8352	0,8823	0,8588	0,8352
F5	0,847	0,847	0,8117	0,8117	0,8235	0,847	0,8352	0,8235	0,8352	0,847	0,8588
F6	0,8	0,8235	0,7764	0,847	0,8352	0,8235	0,8941	0,7882	0,8117	0,7647	0,847
F7	0,8333	0,8095	0,8095	0,8333	0,8333	0,8095	0,7976	0,8333	0,8333	0,8571	0,8333
F8	0,8571	0,8452	0,869	0,869	0,8809	0,9047	0,9166	0,8452	0,8571	0,9047	0,8928
F9	0,8928	0,8214	0,8571	0,8809	0,8571	0,9047	0,9047	0,8571	0,8809	0,8809	0,9404
F10	0,8571	0,8333	0,8571	0,869	0,8928	0,8571	0,8928	0,8809	0,8928	0,8571	0,8571
Ort.	0,8495	0,8186	0,8281	0,8483	0,8566	0,8542	0,8637	0,8329	0,8578	0,8554	0,8637




Şekil 4.5. Kök veri setindeki ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması

Kök veri setindeki ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan doğruluk performans verisi sonuçlarına göre en yüksek ortalama doğruluk değeri 0,8637 olarak ResNet50V2 ve ResNet152V2 derin öğrenme modelleriyle,

en düşük ortalama doğruluk değeri ise 0,8186 ile EfficientNetB1 derin öğrenme modeliyle bulunmuştur. InceptionV3 derin öğrenme modelinin doğruluk değeri 0,8495, EfficientNetB0 derin öğrenme modelinin doğruluk değeri 0,8281, VGG16 derin öğrenme modelinin doğruluk değeri 0,8483, VGG19 derin öğrenme modelinin doğruluk değeri 0,8566, ResNet50 derin öğrenme modelinin doğruluk değeri 0,8542, Xception derin öğrenme modelinin doğruluk değeri 0,8329, DenseNet169 derin öğrenme modelinin doğruluk değeri 0,8578 ve DenseNet201 derin öğrenme modelinin doğruluk değeri 0,8554'tür (Tablo 4.4 ve Şekil 4.5).

Kök veri setindeki orijinal ve ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verisi sonuçlarının karşılaştırması şekil 4.6'da gösterilmiştir.



Şekil 4.6. Kök veri setindeki orijinal ve ön işlemlili görüntülerin derin öğrenme mimarileriyle bulunan ortalama doğruluk performans verilerinin karşılaştırması

Şekil 4.6'da görüldüğü gibi EfficientNetB0 derin öğrenme modelinin orijinal ve ön işlemlili görüntüler üzerindeki ortalama doğruluk performans verileri arasında herhangi bir farklılık görülmemektedir. Bununla birlikte ResNet50,

ResNet50V2, Xception ve ResNet152V2 derin öğrenme modellerinin ön işlemleri görüntülerdeki ortalama doğruluk performanslarının orijinal görüntülerdeki performanslarından daha yüksek olduğu, buna karşın InceptionV3, EfficientNetB1, VGG16, VGG19, DenseNet169 ve DenseNet201 derin öğrenme modellerinin ise orijinal görüntülerdeki ortalama doğruluk performans verilerinin daha yüksek olduğu görülmektedir (Şekil 4.6).

Gruplara göre majority voting sonucunu veren derin öğrenme yöntem kombinasyonları tablo 4.5'te gösterilmiştir.

Tablo 4.5. Gruplara göre majority voting sonucunu veren derin öğrenme yöntem kombinasyonları

Kök Grup	Kron-Kök Grup
DenseNet169 (Orijinal)	DenseNet169 (Orijinal)
ResNet50V2 (Ön İşlemleri)	ResNet50V2 (Orijinal)
InceptionV3 (Orijinal)	InceptionV3 (Ön İşlemleri)
EfficientNetB1 (Orijinal)	EfficientNetB0 (Orijinal)
VGG16 (Ön İşlemleri)	ResNet152V2 (Ön İşlemleri)
ResNet50 (Orijinal)	
DenseNet201(Ön İşlemleri)	

Gruplara göre majority voting sonucunu veren yöntem kombinasyonlarında, her iki grupta da DenseNet169 derin öğrenme yönteminin orijinal görüntü verileri bulunmaktadır. ResNet50V2 derin öğrenme yöntemi kron-kök grubunun orijinal görüntü verisinde ve kök grubunun ön işlemleri görüntü verisinde kullanılarak her iki grupta da majority voting sonucuna katılan yöntem kombinasyonlarında yer almaktadır. InceptionV3 derin öğrenme yöntemi kök grubunun orijinal görüntü verisinde ve kron-kök grubunun ön işlemleri görüntü verisinde kullanılarak her iki grupta da majority voting sonucuna katılan yöntem kombinasyonlarında yer almaktadır (Tablo 4.5).

Kron-kök ve kök veri setlerinin orijinal, ön işlemleri görüntülerinin ve majority voting değerlerinin en yüksek ortalama doğruluk performans sonuçları tablo 4.6'da verilmiştir.

Tablo 4.6. Kron-kök ve kök veri setlerinin orijinal, ön işlemlili görüntülerinin ve majority voting değerlerinin en yüksek ortalama doğruluk performans sonuçları

	Orijinal	Ön İşlemlili	Majority Voting
Kron-kök	0,885	0,886	0,902
Kök	0,892	0,887	0,897

Kron-kök veri setimizdeki orijinal görüntüler 11 farklı derin öğrenme algoritması ile test edilmiş, bütün kombinasyonlar denenerek en yüksek ortalama doğruluk değeri ResNet50V2, VGG16, InceptionV3, DenseNet169 ve ResNet152V2 derin öğrenme mimarilerinin kombine kullanımıyla 0,885 (%88,5) olarak bulunmuştur. Yine kron-kök veri setimizdeki ön işlemlili görüntüler 11 farklı derin öğrenme algoritması ile test edilmiş, bütün kombinasyonlar denenerek en yüksek ortalama doğruluk değeri ResNet50, InceptionV3, DenseNet169 ve ResNet152V2 derin öğrenme mimarilerinin kombine kullanımı ile 0,886 (%88,6) olarak bulunmuştur. Kron-kök veri setimizdeki tüm görüntülerin random majority (çoğunluk oylaması) yöntemiyle derin öğrenme algoritmalarının bütün kombinasyonlarının denemesi sonucu ResNet50V2 (orijinal görüntülerde), EfficientNetB0 (orijinal görüntülerde), InceptionV3 (ön işlem yapılmış görüntülerde), DenseNet169 (orijinal görüntülerde) ve ResNet152V2 (ön işlem yapılmış görüntülerde) derin öğrenme mimarilerinin kombine kullanımı ile en yüksek doğruluk performans metrik sonucu olan 0,902 (%90,2) değeri bulunmuştur. Bu sonuçlara göre kron-kök veri setinde tüm kombinasyonlarda yer alan derin öğrenme yöntemleri InceptionV3, DenseNet169 ve ResNet152V2'dir (Tablo 4.5 ve Tablo 4.6).

Kök veri setimizdeki orijinal görüntüler 11 farklı derin öğrenme algoritması ile test edilmiş, bütün kombinasyonlar denenerek en yüksek ortalama doğruluk değeri ResNet50V2, VGG16, VGG19, Xception, InceptionV3, DenseNet201 ve ResNet152V2 derin öğrenme mimarilerinin kombine kullanımıyla 0,892 (%89,2) olarak bulunmuştur. Kök veri setimizdeki ön işlemlili görüntüler 11 farklı derin öğrenme algoritması ile test edilmiş, bütün kombinasyonlar denenerek en yüksek ortalama doğruluk değeri ResNet50V2, VGG19 ve ResNet152V2 derin öğrenme mimarilerinin kombine kullanımı ile 0,887 (%88,7) olarak bulunmuştur. Kök veri setimizdeki tüm görüntülerin random majority (çoğunluk oylaması) yöntemiyle


derin öğrenme algoritmalarının bütün kombinasyonlarının denenmesi sonucu en yüksek ortalama doğruluk değeri 0,897 (%89,7) olarak bulunmuştur. Random majority yöntemiyle derin öğrenme algoritmalarının bütün kombinasyonları denenmiştir ve ResNet50 (orijinal görüntülerde), ResNet50V2 (ön işlem yapılmış görüntülerde), VGG16 (ön işlem yapılmış görüntülerde), EfficientNetB1 (orijinal görüntülerde), InceptionV3 (orijinal görüntülerde), DenseNet169 (orijinal görüntülerde) ve DenseNet201 (ön işlem yapılmış görüntülerde) derin öğrenme mimarilerinin kombine kullanımı sonucu en yüksek doğruluk performans metrik değerine ulaşılmıştır. Bu sonuçlara göre kök veri setinde tüm kombinasyonlarda yer alan derin öğrenme yöntemi ResNet50V2'dir (Tablo 4.5 ve Tablo 4.6).

Gruplar arası çoğunluk oylaması olmadan derin öğrenme yöntem kombinasyonları denenerek en yüksek ortalama doğruluk değeri kök grubunun orijinal görüntü verisinde, en düşük ortalama doğruluk değeri ise kron-kök grubunun orijinal görüntü verisinde bulunmuştur. Sonuçlar kron-kök grubunun orijinal ve ön işleme veri setlerinde derin öğrenme mimarilerinin kombine kullanımı ile elde edilen ortalama doğruluk değerlerinin, kök grubunun orijinal ve ön işleme veri setlerinde derin öğrenme mimarilerinin kombine kullanımı ile elde edilen ortalama doğruluk değerlerine göre daha düşük olmasına rağmen; kron-kök veri setinin tamamında derin öğrenme mimarilerinin kombine kullanımı ile elde edilen majority voting (çoğunluk oylaması) ortalama doğruluk performans değerinin daha yüksek olduğunu göstermiştir. Ayrıca sonuçlar kron-kök grubunda görüntü verisi üzerinde ön işleme yapıldığında, derin öğrenme mimarilerinin kombine kullanımı ile elde edilen ortalama doğruluk değerinin arttığını; kök grubunda görüntü verisi üzerinde ön işleme yapıldığında derin öğrenme mimarilerinin kombine kullanımı ile elde edilen ortalama doğruluk değerinin azaldığını göstermiştir (Tablo 4.6).


Gruplara göre majority voting sonuçları için diğer performans sonuçları (kesinlik, duyarlılık, özgüllük ve F1 skoru) tablo 4.7'de ve performans sonuçlarının karışıklık matrisi değerleri şekil 4.7 ve 4.8'de gösterilmiştir.

Tablo 4.7. Gruplara göre majority voting sonuçları için diğer performans sonuçları

Performans Metrikleri	Kök Grubu	Kron-Kök Grubu
Kesinlik	0,912	0,900
Duyarlılık	0,885	0,903
Özgüllük	0,910	0,901
F1 Skoru	0,898	0,902



Şekil 4.7. Kron-kök grubundaki majority voting için karışıklık matrisi



Şekil 4.8. Kök grubundaki majority voting için karışıklık matrisi

Gruplara göre majority voting (çoğunluk oylaması) sonuçları için kesinlik, duyarlılık, özgüllük ve F1 skoru performans metrik sonuçları da çalışmamızda tespit edilmiş ve karışıklık matrisi şeklinde gösterilmiştir (Şekil 4.7 ve 4.8).

Gruplara göre majority voting sonuçları için kesinlik, duyarlılık, özgüllük ve F1 skoru performans metrik sonuçlarına katılan derin öğrenme yöntemleri de doğruluk performans metriğinde kombine kullanılan derin öğrenme yöntemleri ile aynı olacak şekilde kabul edilmiştir. Yani kron-kök grubunda kesinlik, duyarlılık, özgüllük ve F1 skoru performans metrik değerlerinin majority voting sonucunu veren yöntem kombinasyonlarında bulunan derin öğrenme yöntemleri ResNet50V2 (orijinal), EfficientNetB0 (orijinal), InceptionV3 (ön işlemlili), DenseNet169 (orijinal) ve ResNet152V2 (ön işlemlili)'dir. Kök grubunda kesinlik, duyarlılık, özgüllük ve F1 skoru performans metrik değerlerinin majority voting sonucunu veren yöntem kombinasyonlarında bulunan derin öğrenme yöntemleri ise ResNet50 (orijinal), ResNet50V2 (ön işlemlili), VGG16 (ön işlemlili), EfficientNetB1 (orijinal), InceptionV3 (orijinal), DenseNet169 (orijinal) ve DenseNet201 (ön işlemlili)'dir. Kron-kök grubunda doğruluk majority voting sonucunu veren kombine derin öğrenme yöntemlerinin kesinlik değeri 0,900, duyarlılık değeri 0,903, özgüllük değeri 0,901 ve F1 skoru 0,902 olarak bulunmuştur. Kök grubunda doğruluk majority voting sonucunu veren kombine derin öğrenme yöntemlerinin kesinlik değeri 0,912, duyarlılık değeri 0,885, özgüllük değeri 0,910 ve F1 skoru 0,898 olarak bulunmuştur. Sonuçlara göre kron-kök grubunda majority voting sonuçları için kombine derin öğrenme yöntemlerinin %90 ve üzerinde duyarlılık, doğruluk, özgüllük ve F1 skoru değeri gösterdiği tespit edilmiştir. Kron-kök grubunda doğruluk majority voting sonucunu veren kombine derin öğrenme yöntemlerinin duyarlılık değeri ve F1 skoru kök grubuna göre daha yüksek, kök grubunda doğruluk majority voting sonucunu veren kombine derin öğrenme yöntemlerinin kesinlik ve özgüllük değeri ise kron-kök grubuna göre daha yüksek bulunmuştur (Tablo 4.7).

Kron-kök ve kök gruplarında yapay zekâ algoritmalarının doğruluk değerlerinin sınıf içi korelasyon (Spearman's korelasyonu) katsayısı değerleri ve istatistiksel olarak karşılaştırması tablo 4.8'de verilmiştir.

Tablo 4.8. Kron-kök ve kök gruplarında yapay zekâ algoritmalarının doğruluk değerlerinin sınıf içi korelasyon (Spearman's korelasyonu) katsayısı değerleri ve istatistiksel olarak karşılaştırması

		1	2	ICC Katsayısı	ICC Katsayısı p Değeri
InceptionV3 Kök	r	1,000			
	p	.			
InceptionV3 Kron-Kök	r	0,016	1	0,031	0,482
	p	0,964	.		
EfficientNetB1 Kök	r	1,000			
	p	.			
EfficientNetB1 Kron-Kök	r	0,415	1	0,526	0,141
	p	0,233	.		
EfficientNetB0 Kök	r	1,000			
	p	.			
EfficientNetB0 Kron-Kök	r	0,413	1	0,577	0,108
	p	0,236	.		
VGG16 Kök	r	1,000			
	p	.			
VGG16 Kron-Kök	r	0,481	1	0,628	0,079
	p	0,160	.		
VGG19 Kök	r	1,000			
	p	.			
VGG19 Kron-Kök	r	0,271	1	0,416	0,218
	p	0,449	.		
ResNet50 Kök	r	1,000			
	p	.			
ResNet50 Kron-Kök	r	0,864	1	0,823	0,001**
	p	0,001**	.		
ResNet50V2 Kök	r	1,000			
	p	.			
ResNet50V2 Kron-Kök	r	0,864	1	0,927	0,001**
	p	0,001**	.		
Xception Kök	r	1,000			
	p	.			
Xception Kron-Kök	r	-0,014	1	0,027	0,515
	p	0,970	.		
DenseNet169 Kök	r	1,000			
	p	.			
DenseNet169 Kron-Kök	r	0,747	1	0,850	0,001**
	p	0,001**	.		
DenseNet201 Kök	r	1,000			
	p	.			
DenseNet201 Kron-Kök	r	0,298	1	0,449	0,194
	p	0,403	.		
ResNet152V2 Kök	r	1,000			
	p	.			
ResNet152V2 Kron-Kök	r	0,933	1	0,951	0,001**
	p	0,001**	.		

Spearman'ın korelasyon katsayısı, *p<0,05 **p<0,01

Doğruluk değerlerine göre InceptionV3 kök ile InceptionV3 kron-kök arasında, EfficientNetB1 kök ile EfficientNetB1 kron-kök arasında, EfficientNetB0 kök ile EfficientNetB0 kron-kök arasında, VGG16 kök ile VGG16 kron-kök arasında, VGG19 kök ile VGG19 kron-kök arasında, Xception kök ile Xception kron-kök arasında ve DenseNet201 kök ile DenseNet201 kron-kök arasında istatistiksel olarak anlamlı ilişki ve uyum bulunmamıştır ($p>0,05$), (Tablo 4.8).

Doğruluk değerlerine göre ResNet50 kök ile ResNet50 kron-kök arasında, ResNet50V2 kök ile ResNet50V2 kron-kök arasında, ResNet152V2 kök ile ResNet152V2 kron-kök arasında, DenseNet169 kök ile DenseNet169 kron-kök arasında pozitif yönde yüksek düzeyde istatistiksel olarak anlamlı ilişki bulunmuştur ($p<0,001$). ResNet50 kök ile ResNet50 kron-kök arasında, ResNet50V2 kök ile ResNet50V2 kron-kök arasında, ResNet152V2 kök ile ResNet152V2 kron-kök arasında, DenseNet169 kök ile DenseNet169 kron-kök arasında iyi düzeyde ve istatistiksel olarak anlamlı ilişki bulunmuştur ($p<0,001$), (Tablo 4.8).

Kron-kök veri setindeki yapay zekâ algoritmalarının orijinal veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması tablo 4.9'da gösterilmiştir.

Tablo 4.9. Kron-kök veri setindeki yapay zekâ algoritmalarının orijinal veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması

	Ort±Sd	*X ²	p**
InceptionV3	0,861340±0,0395625	12,166	0,274
EfficientNetB1	0,838890±0,0269819		
EfficientNetB0	0,831700±0,0392332		
VGG16	0,847110±0,0342223		
VGG19	0,858960±0,0535942		
ResNet50	0,863750±0,0283201		
ResNet50V2	0,855420±0,0309543		
Xception	0,832860±0,0299711		
DenseNet169	0,855420±0,0293585		
DenseNet201	0,863740±0,0357621		
ResNet152V2	0,855440±0,0313265		

*Kruskal Wallis Testi, **p>0,05

Kron-kök veri setinin orijinal veri grubunda en yüksek ortalama doğruluk değeri ResNet50 derin öğrenme modeliyle 0,863±0,028 olarak bulunmuştur. Kron-kök veri setinin orijinal veri grubunda en düşük ortalama doğruluk değeri EfficientNetB0 derin öğrenme modeliyle 0,831±0,039 olarak bulunmuştur (Tablo 4.9).

Kron-kök veri setinin orijinal veri grubunda InceptionV3, EfficientNetB1, EfficientNetB0, VGG16, VGG19, ResNet50, ResNet50V2, Xception, DenseNet169, DenseNet201 ve ResNet152V2 derin öğrenme yöntemlerinin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($X^2=12,166$, $p>0,05$), (Tablo 4.9).

Kron-kök veri setindeki yapay zekâ algoritmalarının ön işlemleri veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması tablo 4.10'da gösterilmiştir.

Tablo 4.10. Kron-kök veri setindeki yapay zekâ algoritmalarının ön işlemleri veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması

	Ort±Sd	*X ²	p**
InceptionV3	0,871912±0,042563	8,531	0,577
EfficientNetB1	0,822290±0,0431871		
EfficientNetB0	0,828140±0,0486562		
VGG16	0,844760±0,0468635		
VGG19	0,858970±0,0377074		
ResNet50	0,854280±0,0715472		
ResNet50V2	0,851840±0,0431544		
Xception	0,845940±0,0551072		
DenseNet169	0,853020±0,0472325		
DenseNet201	0,853020±0,0427719		
ResNet152V2	0,864950±0,0442621		

*Kruskal Wallis Testi, **p>0,05

Kron-kök veri setinin ön işlemleri veri grubunda en yüksek ortalama doğruluk değeri InceptionV3 derin öğrenme modeliyle 0,871±0,042 olarak bulunmuştur. Kron-kök veri setinin ön işlemleri veri grubunda en düşük ortalama doğruluk değeri EfficientNetB1 derin öğrenme modeliyle 0,822±0,043 olarak bulunmuştur (Tablo 4.10).

Kron-kök veri setinin ön işlemleri veri grubunda InceptionV3, EfficientNetB1, EfficientNetB0, VGG16, VGG19, ResNet50, ResNet50V2, Xception, DenseNet169, DenseNet201 ve ResNet152V2 derin öğrenme yöntemlerinin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($X^2=8,531$, $p>0,05$), (Tablo 4.10).

Kron-kök veri setindeki görüntülere ön işlem yapıldığında InceptionV3, VGG19, Xception ve ResNet152V2 derin öğrenme mimarilerinin ortalama doğruluk değeri artmıştır. Kron-kök veri setindeki görüntülere ön işlem

yapıldığında EfficientNetB1, EfficientNetB0, VGG16, ResNet50, ResNet50V2, DenseNet169 ve DenseNet201 derin öğrenme mimarilerinin ortalama doğruluk değeri azalmıştır (Tablo 4.9 ve Tablo 4.10).

Kök veri setindeki yapay zekâ algoritmalarının orijinal veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması tablo 4.11’de gösterilmiştir.

Tablo 4.11. Kök veri setindeki yapay zekâ algoritmalarının orijinal veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması

	Ort±Sd*	*X ²	p**
InceptionV3	0,853040±0,0350173 ^a	20,139	0,028
EfficientNetB1	0,823430±0,0287456 ^{ab}		
EfficientNetB0	0,828170±0,0325451 ^{ab}		
VGG16	0,850720±0,0282977 ^{ab}		
VGG19	0,862570±0,0359415 ^c		
ResNet50	0,851900±0,0314402 ^{ab}		
ResNet50V2	0,849440±0,0276536 ^c		
Xception	0,830600±0,0274620 ^{ab}		
DenseNet169	0,867270±0,0342925 ^c		
DenseNet201	0,861330±0,0272842 ^{ab}		
ResNet152V2	0,851930±0,0301251 ^c		

*Kruskal Wallis Testi, **p<0,05, ^{a,b,c} posthoc test (Mann-Whitney U test)

Kök veri setinin orijinal veri grubunda en yüksek ortalama doğruluk değeri DenseNet169 derin öğrenme modeliyle 0,867±0,034 olarak bulunmuştur. Kök veri setinin orijinal veri grubunda en düşük ortalama doğruluk değeri EfficientNetB1 derin öğrenme modeliyle 0,823±0,028 olarak bulunmuştur (Tablo 4.11).

Kök veri setinin orijinal veri grubunda InceptionV3, EfficientNetB1, EfficientNetB0, VGG16, VGG19, ResNet50, ResNet50V2, Xception, DenseNet169, DenseNet201 ve ResNet152V2 derin öğrenme yöntemlerinin

doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmuştur ($X^2=20,139$, $p<0,05$), (Tablo 4.11).

Kök veri setindeki yapay zekâ algoritmalarının ön işlemleri veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması tablo 4.12’de gösterilmiştir.

Tablo 4.12. Kök veri setindeki yapay zekâ algoritmalarının ön işlemleri veriler üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması

	Ort±Sd	*X ²	p**
InceptionV3	0,849500±0,0304823	16,923	0,076
EfficientNetB1	0,818680±0,0194468		
EfficientNetB0	0,828190±0,0402438		
VGG16	0,848340±0,0341449		
VGG19	0,856640±0,0295064		
ResNet50	0,854280±0,0364714		
ResNet50V2	0,863700±0,0427161		
Xception	0,832980±0,0397369		
DenseNet169	0,857800±0,0303806		
DenseNet201	0,855450±0,0541979		
ResNet152V2	0,863740±0,0348711		

*Kruskal Wallis Testi, **p>0,05

Kök veri setinin ön işlemleri veri grubunda en yüksek ortalama doğruluk değeri ResNet152V2 derin öğrenme modeliyle 0,863±0,034 olarak bulunmuştur. Kök veri setinin ön işlemleri veri grubunda en düşük ortalama doğruluk değeri EfficientNetB1 derin öğrenme modeliyle 0,818±0,019 olarak bulunmuştur (Tablo 4.12).

Kök veri setinin ön işlemleri veri grubunda InceptionV3, EfficientNetB1, EfficientNetB0, VGG16, VGG19, ResNet50, ResNet50V2, Xception, DenseNet169, DenseNet201 ve ResNet152V2 derin öğrenme yöntemlerinin

doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($X^2=16,923$, $p>0,05$), (Tablo 4.12).

Kök veri setindeki görüntülere ön işlem yapıldığında EfficientNetB0, ResNet50, ResNet50V2, Xception ve ResNet152V2 derin öğrenme mimarilerinin ortalama doğruluk değeri artmıştır. Kök veri setindeki görüntülere ön işlem yapıldığında InceptionV3, EfficientNetB1, VGG16, VGG19, DenseNet169 ve DenseNet201 derin öğrenme mimarilerinin ortalama doğruluk değeri azalmıştır (Tablo 4.11 ve Tablo 4.12).



Yapay zekâ algoritmalarının kron-kök veri setindeki orijinal ve ön işlemlî görüntü verileri üzerindeki doğruluk değêrlerinin istatistiksel olarak karşılaştırması tablo 4.13'te gösterilmiştir.

Tablo 4.13. Yapay zekâ algoritmalarının kron-kök veri setindeki orijinal ve ön işlemlî görüntü verileri üzerindeki doğruluk değêrlerinin istatistiksel olarak karşılaştırması

		N	Mean Rank	Sum of Ranks	U*	p**
InceptionV3	Orijinal	10	10,00	100,00	45,000	0,705
	Ön İşlemlî	10	11,00	110,00		
EfficientNetB1	Orijinal	10	12,40	124,00	31,000	0,149
	Ön İşlemlî	10	8,60	86,00		
EfficientNetB0	Orijinal	10	10,50	105,00	50,000	1,000
	Ön İşlemlî	10	10,50	105,00		
VGG16	Orijinal	10	10,70	107,00	48,000	0,879
	Ön İşlemlî	10	10,30	103,00		
VGG19	Orijinal	10	10,85	108,50	46,500	0,790
	Ön İşlemlî	10	10,15	101,50		
ResNet50	Orijinal	10	11,25	112,50	42,500	0,569
	Ön İşlemlî	10	9,75	97,50		
ResNet50V2	Orijinal	10	10,65	106,50	48,500	0,909
	Ön İşlemlî	10	10,35	103,50		
Xception	Orijinal	10	9,40	94,00	39,000	0,405
	Ön İşlemlî	10	11,60	116,00		
DenseNet169	Orijinal	10	11,00	110,00	45,000	0,705
	Ön İşlemlî	10	10,00	100,00		
DenseNet201	Orijinal	10	11,25	112,50	42,500	0,570
	Ön İşlemlî	10	9,75	97,50		
ResNet152V2	Orijinal	10	10,15	101,50	46,500	0,790
	Ön İşlemlî	10	10,85	108,50		

*Mann Whitney U Testi **p>0,05

Kron-kök veri setinde orijinal ve ön işlemlî gruplarda InceptionV3 yönteminin doğruluk değêrleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır (p>0,05). Kron-kök veri setinde orijinal ve ön işlemlî gruplarda EfficientNetB1 yönteminin doğruluk değêrleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır (p>0,05). Kron-kök veri setinde orijinal ve ön işlemlî

gruplarda EfficientNetB0 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kron-kök veri setinde orijinal ve ön işlemlili gruplarda VGG16 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kron-kök veri setinde orijinal ve ön işlemlili gruplarda VGG19 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kron-kök veri setinde orijinal ve ön işlemlili gruplarda ResNet50 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kron-kök veri setinde orijinal ve ön işlemlili gruplarda ResNet50V2 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kron-kök veri setinde orijinal ve ön işlemlili gruplarda Xception yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kron-kök veri setinde orijinal ve ön işlemlili gruplarda DenseNet169 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kron-kök veri setinde orijinal ve ön işlemlili gruplarda DenseNet201 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kron-kök veri setinde orijinal ve ön işlemlili gruplarda ResNet152V2 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$) (Tablo 4.13).

Yapay zekâ algoritmalarının kök veri setindeki orijinal ve ön işlemleri görüntü verileri üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması tablo 4.14'te gösterilmiştir.

Tablo 4.14. Yapay zekâ algoritmalarının kök veri setindeki orijinal ve ön işlemleri görüntü verileri üzerindeki doğruluk değerlerinin istatistiksel olarak karşılaştırması

		N	Mean Rank	Sum of Ranks	U*	p**
InceptionV3	Orijinal	10	10,45	104,50	49,500	0,970
	Ön İşlemleri	10	10,55	105,50		
EfficientNetB1	Orijinal	10	10,75	107,50	47,500	0,850
	Ön İşlemleri	10	10,25	102,50		
EfficientNetB0	Orijinal	10	10,10	101,00	46,000	0,761
	Ön İşlemleri	10	10,90	109,00		
VGG16	Orijinal	10	10,50	105,00	50,000	1,000
	Ön İşlemleri	10	10,50	105,00		
VGG19	Orijinal	10	11,40	114,00	41,000	0,495
	Ön İşlemleri	10	9,60	96,00		
ResNet50	Orijinal	10	10,35	103,50	48,500	0,909
	Ön İşlemleri	10	10,65	106,50		
ResNet50V2	Orijinal	10	9,10	91,00	36,000	0,289
	Ön İşlemleri	10	11,90	119,00		
Xception	Orijinal	10	9,90	99,00	44,000	0,649
	Ön İşlemleri	10	11,10	111,00		
DenseNet169	Orijinal	10	11,65	116,50	38,500	0,383
	Ön İşlemleri	10	9,35	93,50		
DenseNet201	Orijinal	10	10,40	104,00	49,000	0,940
	Ön İşlemleri	10	10,60	106,00		
ResNet152V2	Orijinal	10	9,90	99,00	44,000	0,649
	Ön İşlemleri	10	11,10	111,00		

*Mann Whitney U Testi **p>0,05

Kök veri setinde orijinal ve ön işlemleri gruplarda InceptionV3 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır (p>0,05). Kök veri setinde orijinal ve ön işlemleri gruplarda EfficientnetB1

yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kök veri setinde orijinal ve ön işlemleri gruplarda EfficientnetB0 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kök veri setinde orijinal ve ön işlemleri gruplarda VGG16 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kök veri setinde orijinal ve ön işlemleri gruplarda VGG19 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kök veri setinde orijinal ve ön işlemleri gruplarda ResNet50 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kök veri setinde orijinal ve ön işlemleri gruplarda ResNet50V2 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kök veri setinde orijinal ve ön işlemleri gruplarda Xception yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kök veri setinde orijinal ve ön işlemleri gruplarda DenseNet169 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kök veri setinde orijinal ve ön işlemleri gruplarda DenseNet201 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$). Kök veri setinde orijinal ve ön işlemleri gruplarda Resnet152V2 yönteminin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$) (Tablo 4.14).

5.TARTIŞMA

Dişlerin kök ve kanal yapılarının incelenmesinde ve anatomik varyasyonlarının tespitinde geleneksel radyografi, kanal boyama ve şeffaflaştırma, taramalı elektron mikroskobu ve plastik rezin enjeksiyonu gibi birçok teknik kullanılmıştır.¹³⁶⁻¹³⁹ Bu amaç doğrultusunda, çekilmiş dişler üzerinde daha çok şeffaflaştırma metodu olmak üzere, kesit alma metodu ve boya filtrasyon metodu ile birçok çalışma yapılmıştır.^{136,137,139} Öte yandan çekilmiş dişlerin tanımlanması ile ilgili bilgiye ulaşmakta zorluklar yaşanabildiği belirtilmiştir.¹³⁶ Ex vivo yöntemlerdeki süreçler sırasında, pulpa-dentin kompleksinde meydana gelen değişikliklerin kök kanal morfolojisini etkileyebileceği ve kesit hazırlama aşamalarında örneklerin zarar görebileceğinden bahsedilmiştir.¹⁴⁰ Mikro bilgisayarlı tomografi (MikroCT) ile yapılan çalışmalar, güvenilirliği yüksek ve hasar oluşturmeyen yöntem olarak ön plana çıkmaktadır; ancak cihaz yapısı itibariyle in vitro sınırlaması içerisinde bulunmaktadır.¹⁴¹ Ancak yakın zamanda teknolojik gelişmelere paralel olarak geliştirilen KIBT, morfolojik analizlerde ve endodontik uygulamalarda özellikle kök-kanal yapılarının değerlendirilmesinde etkin olarak kullanılmaktadır.^{142,143} KIBT, üç farklı düzlemde kesitsel görüntüler sunduğu için anatomik yapıların süperpoze olmasını engellemekte ve görüntülenmek istenilen alanı net bir şekilde ortaya koymaktadır. Ayrıca KIBT, hem invaziv bir yöntem olmaması hem de çekilmiş dişlere ihtiyaç duyulmaması açısından avantajlı bir yöntemdir.¹⁴⁴

C şekilli kök kanal sistemine sahip dişlerin kök yüzeyinde bulunan derin oluklar, kök kanal tedavisi aşamasında komplikasyonlara neden olabilmektedir.¹⁴⁵ Yapılan çalışmalarda çoğunlukla kökün bukkal yüzeyinde derin oluk tespit edilmiştir.¹⁴⁵⁻¹⁴⁷ Ancak Zheng ve arkadaşları¹⁴⁴ yaptıkları çalışmada hiç bukkal oluğa rastlamadıklarını rapor etmişlerdir. Enine kesitlerle yapılan çalışmalarında Melton ve arkadaşları⁷, bu kök kanal sistemlerini üç kategoride incelemiştir. İlerleyen yıllarda Fan ve arkadaşları,²¹ bu sınıflamayı kategoriler arasında daha belirgin bir ayırım yapılabilecek şekilde düzenlemişler ve C şekilli kanal tanımı için bazı kriterler önermişlerdir. Bu kriterlerde önemli noktalar, birbirine kaynaşmış görülen köklerde kök yapısı üzerinde bukkal ya da lingual yüzeyde oluk olması ve enine kesitlerden en az birinde önerdikleri kategorilerden birinin tespit

edilebilmesidir. Ayrıca kanal ağzında karşılaşmış olan bu anormal morfolojinin kök apeksine kadar “C” şeklinde süreklilik gösterip göstermeyeceğini klinik olarak tahmin etmek güçtür ve apikale doğru farklı kesitsel morfolojik özellikler sergileyebilmektedirler.^{20,21}

İlk yapılan çalışmalarda Cooke ve Cox¹⁷ C şekilli kanalların radyografilerden teşhis edilmesinin olanaksız olduğunu savunmuşlardır. Lambrianidis ve arkadaşları²⁸ C şekilli kanallara sahip 480 olgu içeren klinik çalışmalarında, az sayıda olgunun radyografi ile teşhis edildiğini bildirmişlerdir. Diğer taraftan, Fan ve arkadaşları¹⁹ ve Jerome²² panoramik radyografiden C şekilli kanalların varlığının ve konfigürasyonunun teşhis edilebileceğini bildirmişlerdir. Ancak intraoral ve panoramik radyografilerden sınırlı bilgi edinilebildiğini, çünkü mezial ve distal kökleri bağlayan dentin çok ince olduğunda veya kemik trabekül kalınlığına bağlı olarak C şekilli kanalların radyolojik teşhisinin zorlaştığını belirtmişlerdir.^{19,22}

2014 yılında yapılan bir çalışmada ise Sinanoğlu ve Helvacıoğlu-Yiğit²⁰ panoramik ve KIBT görüntülemeyi beraber kullanarak, mandibular ikinci azı dişlerindeki C şekilli kanal sistemlerinin özelliklerini araştırmışlardır. Hem rutin KIBT hem de panoramik incelemelerine tabi tutulan 200 hastayı (94 erkek ve 106 kadın) incelemişlerdir. Bir endodontist ve bir oral radyolog, 339 mandibular ikinci molar dişteki C şekilli kanalların KIBT görüntülemeyle sınıflandırmalarını (C1-C2-C3-C4-C5) ve panoramik radyografiyle kök morfolojisi (kaynaşmamış veya kaynaşmış) sınıflandırmalarını tespit etmişlerdir. KIBT görüntülerinden üç farklı seviyede (koronal, orta ve apikal) kesitsel kök kanalı konfigürasyonlarını (C1-C2-C3-C4-C5) belirlemişlerdir. Yaptıkları çalışmada 339 dişin 29'unda (%8,6) C şekilli kök kanal sistemi tespit edilmiş olup, kök kanallarının %86'sı kaynaşmamış olarak tespit edilmiştir. Kaynaşmış kategorisinde C şekilli kanala sahip 23 mandibular ikinci büyük azı diş tespit etmişlerdir. KIBT görüntülemesine göre en yaygın konfigürasyon tüm düzeylerde C3'tür ve C5 vakası tespit edilmemiştir. Sonuçlara göre panoramik radyografi kullanımının, C şekilli kök kanal sistemlerinin tanınmasına ve teşhis edilmesine yardımcı olabileceğini ve radiküler füzyon veya yakınlığın, C şekilli kanal sistemlerinin karakteristik bir özelliği olduğunu belirtmişlerdir. Ayrıca panoramik radyografilerde bu sınıflamaya ek

olarak konverjan yapı gösteren, ancak birbirinden ayrı kök yapısına sahip dişlerden de C şekilli kanal varlığı açısından şüphelenilmesi gerektiğini belirtmişlerdir. İleri görüntüleme sistemleri açısından değerlendirildiğinde, C şekilli kanal sistemlerinin değerlendirilmesi için enine kesitlerin araştırılmasının KIBT ile mümkün olduğunu ve aksiyal düzlemde kök yapısının segmental olarak incelenmesinin morfolojik özelliklerin ortaya konmasında yardımcı olduğunu belirtmişlerdir.

Arslan ve arkadaşları¹⁴⁸ yaptıkları çalışmada, bir grup Türk popülasyonunda mandibular birinci ve ikinci molar dişlerdeki C şekilli kanalların prevalansını, simetrisini, konfigürasyonunu ve radiküler oluk tipini KIBT görüntüleri kullanarak değerlendirmişlerdir. Çalışmada 442 (202 erkek ve 240 kadın) hastada, mandibular birinci ve ikinci molar dişlerin KIBT görüntülerini incelemişler ve dişlerin köklerini koronal, orta ve apikal olmak üzere üç farklı bölgede aksiyal kesitler kullanarak analiz etmişlerdir. C şekilli kanal konfigürasyonunun varlığını ve sınıflandırılmasını, Fan ve arkadaşlarının¹⁹ kriterlerine göre dört kategoride değerlendirmişlerdir. Sonuçlara göre Türk subpopülasyonunda birinci molar dişlerde C şekilli kanal konfigürasyonu bulunmazken, mandibular ikinci molar dişlerde C şeklinin görülme sıklığı %6,94 olarak bulunmuşlardır. C şekilli kanal varlığı kadınlarda erkeklerden daha yüksek bulunmuştur ve mandibular ikinci molar dişlerde C şekilli kök kanalı sol tarafta daha sık görülmüştür. Koronalde C1 kanal konfigürasyonu (%44,68) ve apikal üçlüde C4 konfigürasyonu (%51,06) prevalansı anlamlı olarak yüksek bulunmuştur ve en sık görülen radiküler oluk tipi %74,47 prevalans ile lingual oluk olarak tespit edilmiştir. Çalışmalarının sonucunda C şekilli kanalın varyasyonunda cinsiyet ve simetri faktörlerinin etkili olduğu sonucuna varmışlardır. Bu nedenle KIBT görüntüleri ile diş morfolojisinin üç düzlemde değerlendirilmesinin, tedavi planlaması ve prognoz tahmini açısından çok önemli olduğunu belirtmişlerdir.

Aslan ve arkadaşları¹⁴⁹ 1095 mandibular premolar dişe ait konik ışınli bilgisayarlı tomografi görüntüsünü koronal, orta ve apikal kök seviyelerinde inceleyerek C şekilli anatomisinin tipini, seviyesini ve pozisyonunu (bukkal veya lingual) kaydetmişlerdir. Araştırmada 44 mandibular premolar dişte C şekilli kök kanal morfolojisi saptamışlardır. Mandibular birinci ve ikinci premolar dişlerdeki

C şekilli morfolojilerin yüzdesini sırasıyla %6,9 ve %1,6 olarak hesaplamışlar; birinci ve ikinci premolar dişlerin karşılaştırılması sonucu, birinci premolar dişlerin koronal seviyesinde C1 ve C4b tipi konfigürasyonların daha yaygın olduğunu belirlemişlerdir. Buna karşılık, ikinci premolar dişlerde ise C2 tipi konfigürasyonun anlamlı olarak daha yaygın olduğunu gözlemlemişlerdir. Ek olarak, sağ premolar dişlerin koronal seviyesinde C4c tipi konfigürasyonun anlamlı derecede sık görüldüğünü saptamışlardır.

Endodontik tedavi olarak kanal tedavisi yapılması kararı verilen dişlerde, klinik ve radyografik değerlendirmeden sonra ilk aşama giriş kavitesinin açılmasıdır. C şekilli kanallarda karşılaşılan farklı pulpa odası morfolojileri, giriş kavitesi açılması sırasında bir takım iyatrojenik komplikasyonlara yol açabileceğinden, pulpa odası tabanının anatomisini doğru bilmek çok önemlidir.¹⁵⁰ Fan ve arkadaşları²¹ C şekilli kanala sahip mandibular ikinci molar dişlerin %83,3'ünde kanal girişlerinin mine-sement sınırının 2 mm altında, %98,1'inde ise 3 mm altında yer aldığını göstermişlerdir. Krasner ve Rankow¹⁵¹ çekilmiş dişlerin pulpa odaları ve kanal girişlerini inceledikleri çalışmalarında, kanal girişlerinin pulpa odası duvarları ile tabanının birleşiminde bulunduğunu ve pulpa odası tabanının renginin duvarlardan daha koyu olduğunu belirtmişlerdir. Yang ve arkadaşları²⁶ C şekilli kanal olduğu saptanan dişlerde C şekilli kanal girişinin bulunmasının çok yüksek bir olasılık olduğunu belirtmişlerdir.

YZ; problem çözme, nesne tanıma, kelime tanıma ve karar verme gibi insan davranışlarını taklit eden ve karmaşık görevleri yerine getiren makineler aracılığıyla bilgi üreten bilgisayar biliminin yeni bir dalıdır.^{152,153} YZ uygulamaları sağlık, savunma, mühendislik gibi pek çok alanda kullanılmaya ve gelişmeye açık olmakla birlikte arama motorları (Google, Yandex gibi), çevrimiçi asistanlar (Siri, Bixby vs) ve oyunlar (AlphaGo vs) şeklinde günlük yaşamı da etkilemeyi başarmıştır. Sağlık alanında hastalık riskinin tahmin edilmesi, anomalilerin veya patolojilerin tespit edilmesi, hastalığın teşhisi ve prognozunun değerlendirilmesi, anatomik yapıların incelenmesi gibi konular üzerinde YZ teknolojileri geliştirilmeye devam etmektedir.¹⁵²

Derin öğrenme, verilerin birden çok özellik seviyesinin ve temsillerinin öğrenilmesine dayanan bir yapıdır. Derin öğrenmede ardışık yerleştirilen birden

fazla eğitilebilir bölümler vardır ve üst düzeydeki özellikler, alt düzey özelliklerden türetilerek hiyerarşik bir temsil oluşturulmaktadır. Temel olarak derin öğrenme yönteminde verilerin temsilleri önemlidir ve algoritmalar bu temsillerden öğrenmeye çalışır. Bu nedenle veriyi en iyi şekilde temsil eden ve hiyerarşik özellik çıkarımında etkin olan mimariler seçilmektedir.¹⁵⁴ Literatürde “LeNet, Xception, DenseNet, AlexNet, ZFNet, EfficientNet, VGG, GoogleNet, ResNet, R-CNN, Fast R-CNN ve Faster R-CNN” gibi derin öğrenme mimarilerinin olduğu bildirilmektedir.^{110,112,113,131} Bu mimarilerin sınıflandırma, nesne algılama ve anlamsal bölümleme gibi çeşitli işlevleri bulunmaktadır. Derin öğrenme modelleri, sınıflandırma, algılama ve segmentasyon dahil olmak üzere çeşitli görüntü analizlerinde mükemmel performans göstermişlerdir. Derin öğrenme modelleri kullanılarak hem iki boyutlu (periapikal, bitewing, panoramik) hem de üç boyutlu (KIBT) görüntüler üzerinde yapılan araştırmalarda, dişleri otomatik tanıma ve sınıflandırma, diş yüzeylerindeki çürükleri tespit etme, periapikal görüntülerdeki lezyonların teşhisi, periodontal kemik rezorpsiyonunun tespiti ve miktarı, ağız içi anatomik yapıların incelenmesi, osteoporoz tanısı, görüntü segmentasyonu, hastalığın seyrinin tahmin edilmesi, çene kist veya tümör tespit ve teşhisi, ortodontik analizler, gömülü üçüncü molar diş pozisyonlarının tespiti ve mandibular C şekilli kanalların tespiti yapılmıştır.^{123,124}

YZ’nın eğitim prosedürü sırasında ne kadar çok veri uygulanırsa, gözlemlenen algılama hataları o kadar küçük olur ve daha iyi performans gösterir. Özellikle dijital görüntülerin ortaya çıkmasıyla birlikte görüntülerin bilgisayar diline kolayca çevrilebilmesi sayesinde radyoloji alanı, YZ teknolojileri için gerekli olan büyük veri ihtiyacını karşılamaktadır.^{155,156} Yakın tarihli çalışmalar, sonuçları doğruluk, duyarlılık, özgüllük gibi parametreler ile değerlendirmiştir.^{157,158} Bazı araştırmalarda derin öğrenme modellerinin ve diş hekimlerinin performansı karşılaştırılırken, diğerlerinde birkaç derin öğrenme modelinin performansı karşılaştırılmıştır. Derin öğrenme modellerini diş hekimleriyle karşılaştıran çalışmalarda, derin öğrenme modelleri en azından benzer veya daha iyi performans değerleri göstermiştir.^{5,157,159} Moon ve arkadaşları¹⁶⁰ bir derin öğrenme sistemini pratik kullanım amacıyla yeterince eğitmek için ne kadar öğrenme verisinin gerekli olabileceğini araştırmışlardır. Yaptıkları çalışmada derin öğrenme sistemlerinin tespit hatalarının sadece

öğrenme verilerinin miktarı ile değil, aynı zamanda görüntü başına tespit edilen hedeflerin sayısı ile de önemli ölçüde ilişkili olduğunu göstermişlerdir.

Oktay¹⁶¹ yaptığı çalışmada, ağız boşluğu belirlendikten sonra diş tiplerinin klasik yapay sinir ağları ile tanımlamasını ortaya koymuştur. İlk olarak ağız boşluğunu belirledikten sonra, üç diş tipi için (kesici dişler, küçük azılar ve büyük azılar) uygun pozisyonları saptamıştır. Dişleri, çoklu sınıflandırmaya imkân veren AlexNet mimarisinin modifiye bir versiyonu ile tespit etmiş ve yöntemin doğruluğunun %90'ın üzerinde olduğunu göstermiştir.

Poonsri ve arkadaşları¹⁶² panoramik radyografilerde şablon eşleştirme ile diş segmentasyonu gerçekleştirmişlerdir. Bu çalışmada görüntü işleme teknikleri ile diş bölgelerini tanımlamışlar ve ardından segmentlere ayırmışlardır. Yaptıkları çalışmada diş hekimliğinde YZ çalışmaları kapsamında diş ve diş olmayan alanların segmentasyonunun yapılabileceğinin ve muayene süresinin optimize edilebileceğinin sonucuna ulaşmışlardır.

Leite ve arkadaşları¹⁶³ 153 adet panoramik radyografi görüntüsünü bölütleyerek dişleri sınıflandırmışlardır. YZ destekli sistemle, genel %98,9 hassasiyet ve %99,6 hassasiyet değeri bulmuşlardır. Dişlerin segmentasyonunda, alt kanin dişleri için hassasiyet ve F1 skoru değerini en yüksek olarak bulmuşlardır.

Silva ve arkadaşları¹⁶⁴, panoramik röntgen görüntülerinde her diş segmentasyon maskelerine ayırmaya yönelik klasik YZ yöntemlerinin kapsamlı bir literatür incelemesini sunmuşlardır. 1500 panoramik görüntü kullanılarak yapılan çalışma sonucunda Mask R-CNN derin öğrenme yönteminin panoramik görüntülerde kullanılan diğer derin öğrenme algoritmalarından daha iyi performansa sahip olduğunu göstermişlerdir.

Qingguang Chen ve arkadaşları¹⁶⁵ yaptıkları çalışmada üç boyutlu dental yüzey model görüntüleri kullanarak derin öğrenme tabanlı oklüzal yüzey morfolojisi analiziyle maksiller ve mandibular premolar-molar dişlerin tiplerini sınıflandırmayı amaçlamışlardır. Hiyerarşik derin öğrenme tabanlı oklüzal yüzey morfolojisi analizi için her görüntüye derin evrişimli üretken rakip ağlar (DCGAN) uygulamışlardır. Maksiller ve mandibular premolar-molar dişlerin sınıflandırılmasında %91,35 doğruluk ve %91,49 hassasiyet değerleri

bulmuşlardır. Çalışmada Grad-CAM sonuçları, tüberkül, fossa ve oluk gibi anatomik işaretlerin, basamaklı sınıflandırma modeli için önemli bölgeler olarak çalıştığını göstermiştir. Ayrıca derin öğrenme modellerini eğitmek için geleneksel ve derin evrişimli üretken rakip ağ tabanlı artırılmış görüntülerin birleştirilmesinin sınıflandırma performansını artırabileceğini tespit etmişlerdir.

Hiraiwa ve arkadaşları¹⁵⁷ yaptıkları çalışmada panoramik radyografilerde mandibular birinci molar dişlerin kök morfolojisinin sınıflandırılması için iki farklı derin öğrenme sisteminin tanısal performansını araştırmışlardır. KIBT'yi altın standart olarak kullanmışlar ve kanal tedavisi görmemiş 400 hastanın 760 alt birinci azı dişinin KIBT görüntülerini ve panoramik radyografilerini analiz etmişlerdir. KIBT görüntüleri üzerinde distal kökleri inceleyerek tek veya ekstra kök varlığını tespit etmişlerdir. Eğitim ve test veri seti üzerinde AlexNet ve GoogleNet mimarilerini ayrı ayrı kullanarak kök morfolojisinin sınıflandırılmasındaki tanısal performanslarını incelemişlerdir. Eğitim verisindeki görüntülerin parlaklığını, kontrastını, dönüşünü ve keskinliğini değiştirerek veri sayısını artırmışlar ve tekli ve ekstra kök grupları için katlama başına sırasıyla 11472 ve 11004 eğitim görüntüsü yaması oluşturmuşlardır. Çapraz doğrulama seti, farklı optimize edilmiş parametrelerle sınıflandırılmış olabileceği için beş katlı prosedürün ortalamasını, performans tahmini olarak kabul etmişlerdir. AlexNet ve GoogleNet derin öğrenme sistemlerinin doğruluğunu, duyarlılığını ve özgüllüğünü hesaplamışlardır. AlexNet derin öğrenme sistemi 0,874 doğruluk, 0,773 duyarlılık ve 0,971 özgüllük değeri; GoogleNet derin öğrenme kullanan sistem ise 0,853 doğruluk, 0,742 duyarlılık ve 0,959 özgüllük değeri göstermiştir. AlexNet ve GoogleNet derin öğrenme sistemlerinin AUC (Area Under Curve)'leri sırasıyla 0,87 ve 0,85 iken; radyologların ise 0,74 olarak bulunmuştur. Bu sonuca göre derin öğrenme sistemlerinin AUC değerleri ile radyologların AUC değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmuştur. Derin öğrenme sistemleri, distal köklerin tek mi yoksa ekstra köklere mi sahip olduğunun belirlenmesinde ortalama %86,9 tanısal doğruluğa sahip bulunmuştur. Bizim çalışmamızda olduğu gibi, bu çalışmada da görüntü yamaları çok büyük olmayacak şekilde diş köklerini içine alacak büyüklükte sabitlenmiştir. Çok küçük yamalar yeterli anatomik bilgi sağlamayabilirken, çok büyük yamalar çevreden gelen yanıltıcı bilgiler nedeniyle yüksek eğitim hatalarına neden olabilir. Yine derin öğrenme, sağlıklı hastalardan

elde edilmesi kolay olan panoramik radyografilerle gerçekleştirilmiştir. Bu çalışma bizim çalışmamız gibi panoramik radyografide teşhisleri otomatikleştirmek için derin öğrenme mimarilerini kullanmayı amaçlayan bir dizi çalışmadan biridir. Gelecekte derin öğrenme sistemi, endodontik tedavi için vazgeçilmez kabul edilen periapikal radyografiye de daha fazla uygulanarak, kök kanal morfolojisinin sınıflandırılmasının iyileştirilmesi beklenebilir.

Su Jin Jeon ve arkadaşları¹²⁵ panoramik radyografilerde mandibular ikinci molar dişlerdeki C şekilli kanalları tespit etmek için Xception derin öğrenme sisteminin performansını değerlendirmişler, 2040 mandibular ikinci azı diş veri setini, 887 C şekilli kanal ve 1153 C şekilli olmayan kanal olarak ayırmışlardır. C şekilli bir kanalın varlığını doğrulamak için KIBT görüntüleri bir radyolog tarafından analiz edilmiş ve altın standart olarak belirlenmiştir. Radyolog, sağ ve sol mandibular ikinci azı dişlerinin kronunu ve köklerini tam olarak içeren ilgili dikdörtgen bölgeleri etiketlemiştir. Veri setini eğitim ve test setine bölerek 887 adet C şekilli kanallı panoramik görüntüden 710 adet görüntüyü eğitim setine, 177 adet görüntüyü test setine ve C şekilli olmayan kanallar için ise 922 görüntüyü eğitim setine, 231 görüntüyü test setine dahil etmişlerdir. Yaptıkları çalışmada teşhis performansını, doğruluk, duyarlılık, özgüllük, kesinlik ve eğri altındaki alan (AUC) değerlerini kullanarak değerlendirmişlerdir. Ayrıca, tahminlere katkıda bulunan diş üzerindeki anatomiye lokalize etmek için gradyan ağırlıklı sınıf aktivasyon haritalarını (Grad-CAM) kullanmışlardır. Xception derin öğrenme modelinin doğruluğunu, duyarlılığını, özgüllüğünü ve kesinliğini sırasıyla 0,951, 0,927, 0,970 ve 0,959 olarak bulmuşlardır. Yaptıkları çalışmada Xception derin öğrenme sisteminin, panoramik radyografilerde mandibular ikinci büyük azı dişlerdeki C şekilli kanalları tespit etmede yüksek bir doğruluk değerine sahip olduğunu ve Grad-CAM analizi sonucuna göre; Xception derin öğrenme modelinin esas olarak C şekilli kanalları tahmin etmek için dişin apekse yakın kök kanal şekillerini tanımladığını, kök furkasyonunun ise ağırlıklı olarak C şekilli olmayan kanalları tahmin etmek için kullanıldığını göstermişlerdir. Yaptıkları çalışmayla, YZ'nın klinik uygulamalarda kullanılmasıyla panoramik radyografilerde gözden kaçabilecek durumların ortadan kalkmasına katkı sağlayabileceğini göstermişlerdir. Bu çalışmada da bizim çalışmamızda olduğu gibi derin öğrenme modeli önceden kırılan görüntü verisi üzerinde test edilmiş ve

bu durum doğruluk değerin yüksek bulunmasında etkili olmuştur. Çalışmamızın amacı da zaten en yüksek doğruluk değerine ulaşmaktır. Bizim çalışmamızın bu çalışmadan farkı, görüntü verisi üzerindeki diğer dişleri ve alveol kemiği gibi yapıları gereksiz bilgiye neden olmaması için görüntü verimizden çıkarmak amacıyla kırpma işleminin döndürülerek yapılmasıdır. Bizim çalışmamızda Xception derin öğrenme modelinin ortalama doğruluk değeri 0,832860 olarak bulunmuş olup, bu çalışmadan düşük çıkmıştır. Bunun sebebinin, görüntü veri sayımızın azlığı ve döndürerek kırılma işlemi dolayısıyla kısmi görüntü çözünürlük kaybı olduğunu düşünmekteyiz.

Sujin Yang ve arkadaşları¹⁵⁸ yaptıkları diğer bir çalışmada, panoramik radyografilerde mandibular ikinci molar dişin C şekilli kanal anatomisinin sınıflandırılması için nesne tespitinin birleşik kullanımının etkisini değerlendirmeyi ve çok merkezli bir veri seti üzerinde harici bir doğrulama gerçekleştirmeyi amaçlamışlardır. Yaptıkları çalışma, Yonsei Üniversitesi (YU) Diş Hastanesi'ndeki (Seul, Güney Kore) 402 hasta, Aichi Gakuin Üniversitesi (AGU) Diş Hastanesi'nden 100 (Nagoya, Japonya) hasta, Asahi Üniversitesi (ASU) Diş Hastanesi'nden 103 (Mizuho, Japonya) hasta ve Osaka Diş Üniversitesi (ODU) Hastanesi'nden 100 hastanın panoramik görüntüsünden oluşmuştur ve KIBT görüntü verilerini C şekilli kanal tespiti için altın standart olarak kullanmışlardır. Ayrıca diş implantı, kron tedavisi ve kök kanal tedavisi olan mandibular ikinci molarları da çalışmanın dışında tutmayarak tespitlerini amaçlamışlardır. Toplam C şekilli ve C şekilsiz kanala sahip mandibular ikinci azı dişlerinin sayısını YU veri setinde 750, AGU, ASU ve ODU veri setlerinde ise 200 olacak şekilde oluşturmuşlardır. Yine YU veri setinde 360 C şekilli ve 390 C şekilsiz, AGU, ASU, ODU ve düşük çözünürlüklü ODU veri setlerinde ise 100 C şekilli ve 100 C şekilsiz olacak şekilde oluşturmuşlardır. İş akışı birde (1) mandibular ikinci azı dişlerinin görüntü yamalarını hazırlamak için manuel kırpma kullanmışlar ve ardından EfficientNet derin öğrenme yöntemi ile sınıflandırma yapmışlardır. İş akışı ikide (2), otomatik görüntü kırpma ile önceden YOLOv7 derin öğrenme yöntemi ile nesne algılama gerçekleştirilen ve ardından EfficientNet derin öğrenme yöntemi kullanılarak sınıflandırma yapılan iki birleşik yöntem kullanmışlardır. İş akışı üçte (3), YOLOv7 derin öğrenme yöntemi ile panoramik radyografilerden C şekilli kök kanal anatomisini doğrudan

sınıflandırmışlardır. YU veri setini eğitim ve doğrulama, diğer veri setlerini ise test veri seti olarak ayırarak üç iş akışının sınıflandırma performansını, dört harici doğrulama veri kümesinde değerlendirmişler ve karşılaştırmışlardır. AGU veri seti için iş akışları bir, iki ve üçte doğruluk değerlerini sırasıyla 0,770, 0,755 ve 0,839; ASU veri seti için 0,815, 0,870 ve 0,8030; ODU veri seti için 0,775, 0,785 ve 0,820 olarak bulmuşlardır. ODU düşük yoğunluklu görüntü veri seti için iş akışları bir, iki ve üçte doğruluk değerlerini sırasıyla 0,735, 0,730 ve 0,795 olarak bulmuşlardır. Üç iş akışının derin öğrenme sistemlerinin, tüm test veri kümelerinde mandibular ikinci azı dişlerdeki C şekilli kanalları tahmin etmede önemli doğruluk değerleri elde ettiğini bildirmişlerdir. Yaptıkları çalışmada, dört veri kümesi için iş akışları bir, iki ve üçte doğruluk ve çalışma karakteristik eğrisi (AUC) değerleri arasında istatistiksel olarak anlamlı bir farklılığın olmadığı sonucuna ulaşmışlardır. Ayrıca C şekilli kanal anatomisinin sınıflandırılmasında otomatik görüntü kırpmanın, manuel kırpmanın yerini almada etkili olabileceğini ve veri etiketlemede otomasyonun etkisini doğrulamak için daha büyük veri kümelerinin gerekli olduğu sonucuna ulaşmışlardır. Çalışmalarının sonucunda YOLOv7 derin öğrenme sisteminin güçlü bir genelleme yeteneğine sahip olduğunu ve küçük yapısı gereği görüntünün sadece sinir ağına aktarılmasının nihai nesne algılama sonucunun elde edilmesi için yeterli olmasının, bu mimariyi hızlı kıldığını belirtmişlerdir. Bizim çalışmamızda da bu çalışmada olduğu gibi kron-kök grubunun orijinal veri setinde EfficientNet derin öğrenme yöntemi kullanılmış olup, EfficientNet derin öğrenme yönteminin doğruluk değeri bu çalışmadan farklı olarak çalışmamızda otomatik kırpma uygulandığı için daha yüksek doğruluk değerinde (0,831700) bulunmuştur.

Sherwood ve arkadaşları¹²⁸ KIBT kesitlerinden mandibular ikinci azı dişlerdeki C şekilli kanal anatomisini sınıflandırarak U-Net, Rezidüel U-Net ve Xception-U-Net mimarilerinin (kombine kullanım) performans değerlerini karşılaştırmışlardır. C şekilli kanal anatomisine sahip mandibular ikinci molar dişler içeren toplam 135 KIBT görüntüsünden 100'ünü model eğitimi ve doğrulama için, 35 KIBT görüntüsünü ise test için kullanmışlar ve otomatik etiketleme yapmışlardır. Doğru C şekilli kanal sınıflamasını tahmin etmenin ortalama hassasiyetini, tespit doğruluğuna dayalı olarak hesaplamışlardır. Derin öğrenme mimarileri arasında, Xception-U-Net (kombine kullanım) için ortalama

hassasiyet değeri 0,786, rezidüel U-Net için ortalama hassasiyet değeri 0,746 ve U-Net için ortalama hassasiyet değeri 0,720 olarak bulunmuştur. Sonuçlara göre, U-Net derin öğrenme yönteminin test verilerinde en düşük teşhis performansı sunduğu sonucuna varmışlardır ve bunun nedenini rezidüel U-Net ve Xception-U-Net (kombine kullanım) ile karşılaştırıldığında daha az gelişmiş yapısına bağlamışlardır. Yaptıkları çalışmada ayrıca tüm derin öğrenme modellerinin C şekilli kanal sınıflandırmasında, C1 sınıfı için en yüksek hassasiyet değeri, C2 sınıfı için ise en düşük hassasiyet değeri bulmuşlardır. Ayrıca CLAHE'nin görüntülere uygulanmasının, genel derin öğrenme mimarisi etkinliğini ortalama %4,6 artırdığı sonucuna ulaşmışlardır. Çalışmalarının sonucunda, derin öğrenme algoritmalarının KIBT görüntülerinde otomatik olarak C şekilli kanal anatomisini sınıflandırma potansiyeline sahip olduğu sonucuna varmışlardır. Ayrıca daha fazla veri setinin dahil edilmesinin, test verilerinde gözlemlenen bazı performans düşüşlerinin üstesinden gelmeye de yardımcı olacağını ve giriş kesitinin kontrastını artıran CLAHE gibi veri ön işleme uygulamalarıyla performans sonuçlarının artacağını bildirmişlerdir. Bizim çalışmamızda da farklı derin öğrenme mimarileri kullanılmış ve her birinin farklı ağ yapısına ve kombine kullanımlarına bağlı farklı sonuçlar ortaya çıkmıştır. Yine çalışmamızda veri ön işleme yapılan kron-kök grubunda bu çalışmada olduğu gibi performans değeri artmıştır. Bizim çalışmamızda bu çalışmadan farklı olarak panoramik radyografinin kesitsel yetersizliğinden dolayı C şekilli kanalların sınıflandırılması yapılamamıştır. Ayrıca bizim çalışmamızda YZ algoritmalarının kombine kullanımları ile kron-kök ve kök gruplarında orijinal ve ön işlemlili veri setlerinde en yüksek doğruluk değerlerine ulaşmaya çalışılmıştır ve U-Net YZ algoritması kullanılmamıştır.

Sujin Yang ve arkadaşları¹²⁷ yaptıkları çalışmada 372 hastadan 1000 mandibular ikinci moların periapikal ve panoramik görüntülerini toplayarak EfficientNet derin öğrenme sisteminin tanısal performansını, mandibular ikinci molarların C şekilli kanal konfigürasyonu gösterip göstermediğini belirleme yeteneği açısından incelemişlerdir. CNN modelinin altı alt grup üzerindeki tanısal performansının sonuçlarını sırasıyla elde etmişler ve karşılaştırmışlardır. Sonuçları önce kullanılan görüntüye göre hem koronal hem de kök kısmı (taç ve kök grubu) veya yalnızca kök kısmı (yalnızca kök grubu) içeren görüntü olarak iki gruba

ayırılmışlardır. Daha sonra her grubu, kullanılan görüntü verilerinin kaynağına göre kaynağın yalnızca periapikal görüntülerden (periapikal grup), yalnızca panoramik görüntülerden (panoramik grup) veya her iki görüntüden (tüm görüntüler grubu) olması şeklinde gruplara ayırmışlardır. 372 hastanın (740 mandibular ikinci azı dişi) KIBT görüntüleri üzerinde kanal konfigürasyonunun değerlendirilmesini altın standart olarak kabul etmişlerdir. C şekilli olmayan kanal grubunda, sırasıyla eğitim ve test veri setleri olarak katlama başına 504 ve 56 görüntü yaması kullanılırken, C şekilli kanal grubunda eğitim ve test olarak katlama başına 396 ve 44 görüntü yaması kullanmışlardır. Çalışma sonucu EfficientNet derin evrişimli sinir ağı algoritma modelinin hem periapikal hem de panoramik görüntülerde (tüm görüntüler grubu) mandibular ikinci molar dişler arasındaki C şekilli kanal varyasyonunu tahmin etmede yüksek doğruluk gösterdiğini tespit etmişlerdir. Kron ve kök grubunun doğruluk değerini periapikal grupta 0,90, panoramik grupta 0,85 ve tüm görüntü verisinde 0,91 bulmuşlardır. Sadece kök grubunun doğruluk değerini periapikal grupta 0,91, panoramik grupta 0,86 ve tüm görüntü verisinde 0,95 bulmuşlardır. Kron ve kök grubunun AUC'sini periapikal grupta 0,95, panoramik grupta 0,93 ve tüm görüntüler grubunda 0,95 bulmuşlardır. Yalnızca kök grubunun AUC'sini periapikal grupta 0,98, panoramik grupta 0,95 ve tüm görüntüler grubunda 0,99 bulmuşlardır. Kron ve kök grubunun duyarlılığını 0,93 (periapikal), 0,72 (panoramik) ve 0,90 (tüm görüntüler) ve sadece kök grubu için 0,88 (periapikal), 0,85 (panoramik) ve 0,97 (tüm görüntüler) olarak bulmuşlardır. Yaptıkları çalışmada ayrıca EfficientNet derin öğrenme algoritmasının performansını uzman ve genel klinisyen diş hekimlerinin teşhis performanslarıyla karşılaştırmışlardır. Periapikal radyografileri okurken, uzman ve genel klinisyen performans değerlerini sırasıyla doğruluk için 0,95 ve 0,89, duyarlılık için 0,95 ve 0,91 ve AUC için 0,95 ve 0,89 olarak, panoramik görüntüleri okurken uzman ve genel diş hekimi performans değerlerini ise sırasıyla doğruluk için 0,96 ve 0,91, duyarlılık için 0,97 ve 0,93 ve AUC için 0,96 ve 0,91 olarak bulmuşlardır. Sonuçlara göre uzman ve genel diş hekimi teşhis performansını, panoramik radyografiler üzerinde daha yüksek, EfficientNet derin öğrenme yöntemi teşhis performansını ise periapikal radyografiler üzerinde daha yüksek bulmuşlardır. Ayrıca sonuçlara göre AUC performans metriğini karşılaştırdıklarında, uzman diş hekiminin performansının derin öğrenme yöntemine benzer, genel diş hekiminin performansının ise uzman diş hekimi ve derin öğrenme yöntemi ile

karşılaştırıldığında daha düşük değerler gösterdiğini bulmuşlardır. Bununla birlikte, EfficientNet derin öğrenme modeli hem periapikal hem de panoramik radyografilerinin beraber ve yalnızca kök kısmını içeren görüntü yamalarında kullanıldığında, performans ölçümlerinde en iyi performans sonuçlarını elde etmişlerdir. Bunun sebebinin, periapikal ve panoramik görüntülerin yoğunluk ve çözünürlük farkından kaynaklandığı sonucuna varmışlardır. Periapikal görüntüler daha yüksek çözünürlüğe sahiptir, ancak panoramik görüntüler periapikal görüntülerle karşılaştırıldığında büyütme etkisine sahiptir. Bu nedenle tüm görüntüler kullanıldığında, periapikal görüntülerin etkisiyle yoğunlukta ve çözünürlükte artış yapılmış gibi davranarak daha sağlam bir model ve daha iyi performans elde edildiği sonucuna ulaşmışlardır. Eğitim için diş görüntüsünün sadece kök kısmı kullanıldığında hem panoramik hem de periapikal veri setinde performansın daha yüksek olmasının nedenini, kron ve kök kısımlarının her ikisinin de mevcut olduğu görüntü yamalarında dış anatomik yapılar veya kronlar gibi çeşitli protezlerin görüntüsünün, etiketlenen diş görüntüsü üzerine süperpoze olmasının sonucu olduğunu ileri sürmüşlerdir. Bu sonuçlarla daha büyük bir veri seti kullanılarak test verilerinin daha fazla optimizasyonu ve modelde yapılan iyileştirmelerle, bir derin öğrenme sisteminin C şekilli kanalları etkili bir şekilde teşhis etmesinin ve klinisyenlere uygulamada ve eğitimde yardımcı olmasının beklenebileceği sonucunu çıkarmışlardır. Bizim çalışmamızla benzer olarak bu çalışmada da panoramik radyografi veri setinin kron-kök ve kök veri setlerinin orijinal görüntüleri üzerinde EfficientNet derin öğrenme sistemi kullanılmış olup, doğruluk değerleri bizim çalışmamızdan yüksek bulunmuştur. Bizim çalışmamızda da panoramik radyografide derin öğrenme yöntemlerinin kombine kullanımları sonucu, kök grubunun derin öğrenme doğruluk değeri, kron-kök grubunun derin öğrenme doğruluk değerinden fazla bulunmuştur. Biz de bu çalışmada olduğu gibi bunun nedenini kron ve kök kısımlarının her ikisinin de mevcut olduğu görüntü yamalarında dış anatomik yapılar veya kronlar gibi çeşitli protezlerin görüntüsünün etiketlenen diş görüntüsü üzerine kısmen de olsa süperpoze olmasının ve C şekilli kanalların dış kökünde lokalize bulunmasının sonucu olduğunu tahmin etmekteyiz. Bizim çalışmamızda bu çalışmadan farklı olarak, panoramik radyografilerde EfficientNet derin öğrenme sisteminin kök grubunda doğruluk performans değeri, kron-kök grubuna göre daha düşük bulunmuştur ve 11 farklı derin öğrenme mimarisi kullanılarak en yüksek

performans deęerine ulařılmaya alıřılmış olup, sadece panoramik radyografi veri seti kullanılarak kron-kök ve kök veri grubunda orijinal ve ön iřlemli veri setleri iin ayrı ayrı doęruluk performansları deęerlendirilmiřtir.

Mandibular ikinci azı diřlerinde C řekilli bir kök kanalının hızlı ve doęru tespiti, diř hekimlerine tanı ve tedavide yardımcı olabilir. Panoramik radyografi, diřlerin kök kanalını belirlemede en etkili yöntemlerden biridir. C řekilli diř kökü görüntülerinin özelliklerini öğrenmek iin derin öğrenmeye dayalı bazı geleneksel yöntemler halihazırda mevcuttur. Ancak önceki alıřmalar,^{125,127} C řekilli kök kanalını tespit etme doęruluęunun hala iyileřtirilmesi gerektięini göstermiřtir ve sınırlı donanım kaynaklı derin aę yapıları ile bunu gerekleřtirmek uygun deęildir. Lijuan Zang ve arkadařları¹²⁶ öznitelik ıkarımını optimize etmek iin ok ölekli alıcı alan bloęu ile birleřtirilen yeni bir hafif evriřimli sinir aęı tasarlamıřlardır. Yaptıkları alıřmada 384 panoramik görüntüden oluřan veri setindeki mandibular ikinci molar diř ile ilgili alan, beř yıllık mesleki deneyime sahip bir radyolog tarafından manuel kesme yöntemi ile seilmiřtir ve boyutu 90×90 olarak ayarlanmıřtır. İkinci adımda, yapısı zarar görmüř, düşük özünürlüklü ve dięer tatmin edici olmayan diř görüntülerini veri setinden ıkarmıřlardır. Bundan sonra, iki diř hekimi veri setinin ikinci bir incelemesini gerekleřtirmiřler ve son görüntü sayısını 361 adet C řekilli kök kanalı vakası ve 364 adet C řekilli olmayan kök kanalı vakası řeklinde belirtmiřlerdir. Daha sonra görüntü veri setini %70 eęitim ve doęrulama, %30 test grubu řeklinde ayırmıřlardır. alıřmalarında ok ölekli alıcı alan bloklu (RFB) hafif evriřimli sinir aęının mandibular ikinci azı diřlerin görüntü verileri üzerindeki C řekilli kök kanallarını tespit etmede doęruluk ve alıcı alıřma karakteristik eęrisi (AUC) altındaki alan deęerlerini sırasıyla 0,9838 ve 0,996 olarak bulmuřlardır. Yaptıkları alıřmada ayrıca LeNet, VGG16 ve Xception gibi eřitli derin öğrenme yöntemlerinin de performansını deęerlendirmiřlerdir. LeNet'in doęruluęunu ve AUC'sini sırasıyla 0,9117 ve 0,9680; VGG16'nın doęruluęunu ve AUC'sini sırasıyla 0,9712 ve 0,9888; ResNet18'in doęruluęunu ve AUC'sini sırasıyla 0,9784 ve 0,9890 ve Xception'ın doęruluęunu ve AUC'sini sırasıyla 0,9649 ve 0,9860 olarak bulmuřlardır. Sonuçlara göre, ok ölekli alıcı alan bloęu yönteminin ok yüksek performansa ve alıřmada kullanılan dięer derin öğrenme mimarilerine göre daha iyi doęruluęa ve daha düşük kaynak tüketimine sahip olduęunu göstermiřlerdir. Ayrıca bu

yöntemin sonuçlarını çalışmaya katılan iki diş hekimi ile de karşılaştırmışlardır. İki diş hekiminin doğrulukları sırasıyla 0,6352 ve 0,5770, AUC değerleri ise 0,635 ve 0,577 olarak belirlenmiştir. Bu sonuçla önerilen yöntemin iki diş hekiminden çok daha yüksek doğruluğa ve performansa sahip olduğunu göstermişlerdir. Bizim çalışmamızda kullanılan derin öğrenme yöntemlerinin yapısından farklı olarak hafif evrişimli sinir ağındaki çok ölçekli alıcı alan bloğu (RFB), modelin ayrıntılı özellikleri çıkarmasına izin veren çok dallı bir evrişim yapısı kullanır ve farklı boyuttaki evrişim çekirdekleri, farklı alıcı alanlara karşılık gelerek genişletilmiş evrişim katmanları uygular. Bu da hesaplama ve parametre miktarını önemli ölçüde azaltıp veri setinin derin öğrenimini sağlayarak, yüksek performans elde edilmesine olanak verir.

Sujin Yang ve arkadaşları¹⁵⁹ yaptıkları çalışmada karmaşık morfolojileri nedeniyle teşhis edilmesi zor olan C şekilli kök kanallarını sınıflandırmak için üretken çekişmeli ağ (Generative adversarial networks) modeliyle üretilen periapikal görüntülerin performansını değerlendirmişlerdir. Periapikal görüntüleri StyleGAN2-ADA çerçevesi kullanarak oluşturmuşlar ve bunların kalitesini, ortalama Frechet başlangıç mesafesi ve görsel Turing testine göre değerlendirmişlerdir. Sentezlenen C şekilli kanal görüntüleri için ortalama Frechet başlangıç mesafesi değerini 35,353 ($\pm 4,386$), C şekilli olmayan kanal görüntüleri için 25,471 ($\pm 2,779$) olarak bulmuşlardır. Gerçek görüntülerin (280 görüntü) ve GAN ile sentezlenmiş görüntülerin (560 görüntü) olduğu karışık görüntü verisini EfficientNetB0 derin öğrenme yöntemiyle değerlendirmişlerdir. Doğruluk, duyarlılık ve özgüllük değerlerini gerçek görüntü verisinde sırasıyla 0,805, 0,800 ve 0,810 ve karışık görüntü verisinde sırasıyla 0,890, 0,910 ve 0,870 olarak bulmuşlardır. Derin öğrenme yönteminin sınıflandırma performansının, gerçek görüntü verilerinin GAN görüntü verileriyle güçlendirildiğinde, yalnızca gerçek görüntü verilerinin kullanılmasıyla karşılaştırıldığında, iyileşmeler ve tatmin edici görsel kalite sergilediğini göstermişlerdir. Ayrıca GAN ile sentezlenmiş görüntülerin, bulanık görünen apeksler, periodontal kanallar ve daha az belirgin kök kanalları gibi özelliklerden dolayı kökün apikal alanında, kökün orta ve koronal kısmına göre daha düşük hassasiyet ve performans gösterdiğini belirtmişlerdir. GAN'ların gerçekçi görüntüler oluşturmak için umut verici bir teknik olduğunu ve sınırlı eğitim veri setlerine sahip senaryolarda veri artırma için

potansiyel bir çözüm sunduğunu belirtmişlerdir. Bizim çalışmamızda da veriler GAN olmasa da bir veri ön işleme sürecinden geçirilmiş olup, kron-kök veri grubumuzda bu çalışmadaki kadar olmasa da doğruluk performans değeri artış göstermiştir. Bizim çalışma bulgularımızda düşük doğruluk değeri veren EfficientNetB0 ile GAN ile sentezlenmiş görüntülerde yüksek performansa ulaşılması önemlidir ve GAN'ın görüntü verileri üzerindeki etkisi ile ilgili gelecekteki çalışmalar için umut vericidir.

Gün geçtikçe artan veri miktarı da göz önünde bulundurulduğunda, YZ çözümleri sayesinde eksik veya yanlış teşhis oranının düşürülmesi, kanal tedavisi başarısının artması ve hekimlerin iş yükünün azaltılmasının mümkün olacağı öngörülmektedir. Bunun yanı sıra, YZ ile insan gözünden daha ayrıntılı gözlem yapmak mümkün olacaktır. Gelecekte YZ uygulamalarının performans metriklerinin gerçeğe %100 yaklaşması sağlandığı takdirde, panoramik radyografilerde mandibular ikinci molar dişlerdeki C şekilli kanalların derin öğrenme algoritmalarıyla otomatik olarak tespiti ve sınıflandırılması mümkün olacaktır.

Özellikle insan eliyle etiketlenen verileri kullanan veya sınıflar arası dengeli sonuçlar vermeyen yapılarda sınıflandırmalar, sınıf bazında belli çarpanlara sahip olur. Kullanılan başarımların metrikleri de bu dağılımlara uygun olarak gerçekleştirilir. Yapılan çalışmalara bağlı olarak birçok başarımların metriği oluşturulabilir. Çalışmamızda C şekilli olan ve olmayan görüntü veri sayımız eşit olduğu için dengeli veri kümemiz mevcuttur ve doğruluk metriği YZ algoritmalarının performansının değerlendirilmesinde yeterli bilgiyi sağlamaktadır. Çalışmamızda da MATLAB R2021b versiyonlu kırpma programı ile kron-kök ve kök gruplarının hem orijinal hem de ön işlem yapılmış veri setlerindeki her bir görüntü standart olmayan bir açı ile rotasyon yaptırılıp kırpılmış ve derin öğrenme algoritmaları kullanılarak yüksek başarı oranında tahmin edilmiştir. Veri sayısının artması, harici doğrulama ve çok merkezli çalışmalarla beraber, daha yüksek performans değerlerine ulaşılması mümkündür.

Çalışmamızda kron-kök veri setimizdeki orijinal görüntüler 11 farklı derin öğrenme algoritması ile test edilmiş, bütün kombinasyonlar denenerek en yüksek ortalama doğruluk değeri ResNet50V2, VGG16, InceptionV3, DenseNet169 ve

ResNet152V2 derin öğrenme mimarilerinin kombine kullanımıyla 0,885 (%88,5) olarak bulunmuştur. Yine çalışmamızda kron-kök veri setimizdeki ön işlemleri görüntüler 11 farklı derin öğrenme algoritması ile test edilmiş, bütün kombinasyonlar denenerek en yüksek ortalama doğruluk değeri ResNet50, InceptionV3, DenseNet169 ve ResNet152V2 derin öğrenme mimarilerinin kombine kullanımıyla 0,886 (%88,6) olarak bulunmuştur. Kron-kök veri setindeki tüm görüntülerin çoğunluk oylaması yöntemiyle derin öğrenme algoritmalarının bütün kombinasyonlarının denemesi sonucu ResNet50V2 (orijinal görüntülerde), EfficientNetB0 (orijinal görüntülerde), InceptionV3 (ön işlem yapılmış görüntülerde), DenseNet169 (orijinal görüntülerde) ve ResNet152V2 (ön işlem yapılmış görüntülerde) derin öğrenme mimarilerinin kombine kullanımıyla en yüksek doğruluk performans sonucu olan 0,902 (%90,2) değeri bulunmuştur. Bu sonuçlara göre kron-kök veri setinde tüm kombinasyonlarda yer alan derin öğrenme yöntemleri InceptionV3, DenseNet169 ve ResNet152V2'dir.

Çalışmamızda kök veri setimizdeki orijinal görüntüler 11 farklı derin öğrenme algoritması ile test edilmiş, bütün kombinasyonlar denenerek en yüksek ortalama doğruluk değeri ResNet50V2, VGG16, VGG19, Xception, InceptionV3, DenseNet201 ve ResNet152V2 derin öğrenme mimarilerinin kombine kullanımı ile 0,892 (%89,2) olarak bulunmuştur. Yine çalışmamızda kök veri setimizdeki ön işlemleri görüntüler 11 farklı derin öğrenme algoritması ile test edilmiş, bütün kombinasyonlar denenerek en yüksek ortalama doğruluk değeri ResNet50V2, VGG19 ve ResNet152V2 derin öğrenme mimarilerinin kombine kullanımı 0,887 (%88,7) bulunmuştur. Random majority görüntü verimizin derin öğrenme algoritmalarıyla bütün kombinasyonlar denenerek en yüksek ortalama doğruluk değeri 0,897 (%89,7) olarak bulunmuştur. Random majority görüntüler ResNet50 (orijinal görüntülerde), ResNet50V2 (ön işlem yapılmış görüntülerde), VGG16 (ön işlem yapılmış görüntülerde), EfficientNetB1 (orijinal görüntülerde), InceptionV3 (orijinal görüntülerde), DenseNet169 (orijinal görüntülerde) ve DenseNet201 (ön işlem yapılmış görüntülerde) derin öğrenme mimarilerinin kombine kullanımı ile en yüksek doğruluk performans metrik sonucu değerine ulaşılmıştır. Bu sonuçlara göre kök veri setinde tüm kombinasyonlarda yer alan derin öğrenme yöntemi ResNet50V2'dir.

Çalışmamızın sonuçlarına göre gruplar arası çoğunluk oylaması olmadan en yüksek doğruluk değeri kök grubunun orijinal görüntü verisinde, en düşük doğruluk değeri ise kron-kök grubunun orijinal görüntü verisinde bulunmuştur. Sonuçlar kron-kök grubunun orijinal ve ön işleme veri setlerinde derin öğrenme mimarilerinin kombine kullanımı ile elde edilen en yüksek ortalama doğruluk değerlerinin, kök grubunun orijinal ve ön işleme veri setlerinde derin öğrenme mimarilerinin kombine kullanımı ile elde edilen en yüksek ortalama doğruluk değerlerine göre düşük olduğunu göstermesine rağmen; kron-kök veri setinin tamamında derin öğrenme mimarilerinin kombine kullanımı ile elde edilen majority voting (çoğunluk oylaması) değerinin daha yüksek olduğunu göstermiştir. Ayrıca sonuçlar kron-kök grubunda görüntü verisi üzerinde ön işleme yapıldığında derin öğrenme mimarilerinin kombine kullanımı ile elde edilen doğruluk değerinin arttığını, kök grubunda görüntü verisi üzerinde ön işleme yapıldığında derin öğrenme mimarilerinin kombine kullanımı ile elde edilen doğruluk değerinin azaldığını gösterdi. C şekilli kanalların kökte lokalize olması ve kök grubunda dış anatomik yapıların görüntü üzerine daha az süperpoze olması sebebiyle kök veri setinde doğruluk değerlerinin daha fazla bulunduğunu düşünmekteyiz. Kron-kök veri seti üzerinde ön işlem yapıldığında doğruluk değerinin artıp, kök veri seti üzerinde ön işlem yapıldığında doğruluk değerinin azalmasının nedeni derin öğrenme yöntemlerinin yapısal farklılıklarından kaynaklanmaktadır. Yine kron-kök veri setinin tamamında derin öğrenme mimarilerinin kombine kullanımı ile elde edilen majority voting (çoğunluk oylaması) değerinin kök veri setine göre daha yüksek olmasının nedenini kombine kullanılan derin öğrenme yöntemlerinin, tek başına kullanılan derin öğrenme yöntemlerine göre farklı performans göstermesi olarak düşünmekteyiz. Kron-kök veri setinin orijinal veri grubunda en yüksek ortalama doğruluk değeri ResNet50 derin öğrenme modeliyle bulunmasına rağmen kombine sonuçta yer almaması; kök veri setinin orijinal veri grubunda en yüksek ortalama doğruluk değeri DenseNet169 derin öğrenme modeliyle bulunmasına rağmen kombine sonuçta yer almaması; kök veri setinin ön işlemleri grubunda en yüksek ortalama doğruluk değeri ResNet152V2 derin öğrenme modeliyle bulunmasına rağmen kök veri setinin çoğunluk oylamasının (majority voting) kombine sonucunda yer almaması; EfficientNetB0 ve EfficientNetB1 derin öğrenme modellerinin kron-kök ve kök veri setlerinin orijinal ve ön işlemleri görüntülerinde en düşük ortalama doğruluk

değerlerini vermelerine rağmen kron-kök ve kök veri setlerinin çoğunluk oylaması (majority voting) kombine sonuçlarında yer almaları, kombine kullanılan derin öğrenme modellerinin tek başına kullanılan derin öğrenme modellerine göre farklı performans göstermesini açıklar.

Çalışmamızın sınıf içi korelasyon sonuçlarına göre, InceptionV3, EfficientNetB1, EfficientNetB0, VGG16, VGG19, Xception ve DenseNet201 derin öğrenme modellerinin, kron-kök ve kök gruplarındaki doğruluk değerleri arasında istatistiksel olarak anlamlı bir ilişki bulunmazken ($p>0,05$), ResNet50, ResNet50V2, ResNet152V2 ve DenseNet169 derin öğrenme modellerinin kron-kök ve kök gruplarındaki doğruluk değerleri arasında pozitif yönde yüksek düzeyde istatistiksel olarak anlamlı bir ilişki bulunmuştur ($p=0,001$; $p<0,01$).

Araştırmamızda kron-kök veri setinin orijinal veri grubunda en yüksek ortalama doğruluk değeri ResNet50 derin öğrenme modeliyle ($0,863\pm0,028$), en düşük ortalama doğruluk değeri EfficientNetB0 derin öğrenme modeliyle ($0,831\pm0,039$); ön işlemlili veri grubunda ise en yüksek ortalama doğruluk değeri InceptionV3 derin öğrenme modeliyle ($0,871\pm0,042$), en düşük ortalama doğruluk değeri EfficientNetB1 derin öğrenme modeliyle ($0,822\pm0,043$) bulunmuştur. Ancak bu farklılıklara rağmen, kron-kök veri setinin hem orijinal hem de ön işlemlili veri grubunda araştırmaya dahil edilen derin öğrenme yöntemlerinin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$).

Kök veri setinde orijinal veri grubunda en yüksek ortalama doğruluk değeri DenseNet169 derin öğrenme modeliyle ($0,867\pm0,034$), en düşük ortalama doğruluk değeri EfficientNetB1 derin öğrenme modeliyle ($0,823\pm0,028$); ön işlemlili veri grubunda ise en yüksek ortalama doğruluk değeri ResNet152V2 derin öğrenme modeliyle ($0,863\pm0,034$), en düşük ortalama doğruluk değeri EfficientNetB1 derin öğrenme modeliyle ($0,818\pm0,019$) bulunmuştur. Ön işlemlili veri grubunda derin öğrenme yöntemleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamasına rağmen, orijinal veri grubunda istatistiksel olarak anlamlı bir farklılık bulunmuştur ($p<0,05$). Bu farklılığın kök veri setinin orijinal veri grubundaki görüntülerin çözünürlüklerinin düşük olması sebebiyle basit yapıları derin öğrenme mimarilerinin görüntü tespitinde yetersiz kalması ve gelişmiş

yapıdaki derin öğrenme mimarilerinin, dış anatomik yapıların görüntü üzerine süperpoze olmamasından dolayı görüntü tespitinde yüksek doğruluk sonuçları vermesinden kaynaklandığını düşünmekteyiz.

Çalışmamızın sonuçlarına göre kron-kök ve kök gruplarında doğruluk majority voting sonucunu veren kombine derin öğrenme yöntemlerinin kesinlik, duyarlılık, özgüllük ve F1 skoru değerleri kron-kök grubu için sırasıyla 0,900, 0,903, 0,901 ve 0,902; kök grubu için ise sırasıyla 0,912, 0,885, 0,910 ve 0,898 olarak bulunmuştur. Sonuçlara göre kron-kök grubunda majority voting sonuçları için kombine derin öğrenme yöntemlerinin %90 ve üzerinde duyarlılık, kesinlik ve özgüllük gösterdiği tespit edilmiştir.

Çalışmamızda kron-kök veri setindeki görüntülere ön işlem yapıldığında InceptionV3, VGG19, Xception ve ResNet152V2 derin öğrenme modellerinin ortalama doğruluk değeri artmış, EfficientNetB1, EfficientNetB0, VGG16, ResNet50, ResNet50V2, DenseNet169 ve DenseNet201 derin öğrenme modellerinin ortalama doğruluk değeri azalmıştır. Ancak derin öğrenme yöntemlerinin hiçbirinde ön işlemleri ve orijinal veri grupları arasında istatistiksel olarak anlamlı bir farklılık tespit edilmemiştir ($p>0,05$).

Çalışmamızda kök veri setindeki görüntülere ön işlem yapıldığında EfficientNetB0, ResNet50, ResNet50V2, Xception ve ResNet152V2 derin öğrenme modellerinin ortalama doğruluk değeri artmış, InceptionV3, EfficientNetB1, VGG16, VGG19, DenseNet169 ve DenseNet201 derin öğrenme modellerinin ortalama doğruluk değeri azalmıştır. Ancak derin öğrenme yöntemlerinin hiçbirinde ön işlemleri ve orijinal veri grupları arasında istatistiksel olarak anlamlı bir farklılık tespit edilmemiştir ($p>0,05$).

Literatürde YZ algoritmalarıyla yapılan çalışmaların çok farklı algoritmalara dayanması sebebiyle çalışmalar arasında doğrudan bir karşılaştırma yapmak mümkün değildir. Çalışmamız 11 farklı YZ algoritmasının doğruluk performans değerlerinin hem kron-kök ve kök veri setlerinde hem de bu veri setlerinin orijinal ve ön işlem yapılmış gruplarında ayrı ayrı araştırılması ve kombine kullanımları sonucu her bir grupta en yüksek doğruluk performans değerlerinin belirlenmesi açısından bir ilktir. Çalışmamızda doğruluk performans

metriği tespit edilmiş olup, performans sonuçlarının güvenilirliği açısından veri setimizin dağılımı dengelidir.

Bu çalışmanın limitasyonları; YZ algoritmalarının panoramik radyografinin kesitsel yetersizliğinden dolayı C şekilli kanalların sınıflandırılmasının yapılamaması ve tek bir panoramik cihazına ait verilerle C şekilli kanalların YZ algoritmalarına tanıtılmış olmasıdır. Çalışmamızda veri setini oluşturan bütün görüntüler aynı panoramik cihazında, aynı parametrelerle çekilen görüntülerden oluşmaktadır. Farklı cihazlar ve farklı çekim parametreleri uygulanarak elde edilecek görüntülerle yapılacak olan çalışmalar ile daha etkin derin öğrenme modelleri elde edilebilir. Çalışmamızda veri ön işleme derin öğrenme yöntemlerinin ortalama doğruluk değerlerini anlamlı derecede artırmamış olup, bazı derin öğrenme yöntemlerinde veri ön işleme sonucunda ortalama doğruluk değerlerinde düşüş gözlenmiştir. Daha ileri görüntü işleme teknikleri ile yapılacak çalışmalarda derin öğrenme yöntemlerinin doğruluk değerlerinde artış beklenebilir. Çalışmamızda ayrıca derin öğrenme yöntemlerinin yapısal özelliklerinden dolayı tek başına ve kombine kullanımlarında farklı performans sonuçları göstermesi çoğunluk oylaması (majority voting) değerlerinden anlaşılmaktadır. Bulgularımız göz önünde bulundurulduğunda; YZ algoritmalarının mandibular ikinci molar dişlerdeki C şekilli kanalları hem kron-kök grubunda hem de kök grubunda tespit etmede yeterli olduğu, ancak daha fazla veri ve ileri görüntü işleme yöntemleriyle eğitilerek daha da iyileştirilebileceği sonucuna varılabilir.

6.SONUÇ VE ÖNERİLER

Bu çalışmanın bulguları değerlendirildiğinde aşağıda belirtilen sonuç ve öneriler elde edilmiştir:

1. Çalışmamızda kron-kök veri setinin orijinal ve ön işlemleri veri gruplarında derin öğrenme yöntemlerinin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$).
2. Kök veri setinin ön işlemleri veri grubunda derin öğrenme yöntemlerinin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$).
3. Kök veri setinin orijinal veri grubunda derin öğrenme yöntemlerinin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmuştur ($p<0,05$).
4. Kron-kök veri setindeki görüntülere ön işlem yapıldığında InceptionV3, VGG19, Xception ve ResNet152V2 derin öğrenme mimarilerinin ortalama doğruluk değeri artmış, EfficientNetB1, EfficientNetB0, VGG16, ResNet50, ResNet50V2, DenseNet169 ve DenseNet201 derin öğrenme mimarilerinin ortalama doğruluk değeri azalmıştır.
5. Kök veri setindeki görüntülere ön işlem yapıldığında EfficientNetB0, ResNet50, ResNet50V2, Xception ve ResNet152V2 derin öğrenme mimarilerinin ortalama doğruluk değeri artmış, InceptionV3, EfficientNetB1, VGG16, VGG19, DenseNet169 ve DenseNet201 derin öğrenme mimarilerinin ortalama doğruluk değeri azalmıştır.
6. Kron-kök ve kök veri setlerinde orijinal ve ön işlemleri gruplarda InceptionV3, EfficientNetB1, EfficientNetB0, VGG16, VGG19, ResNet50, ResNet50V2, Xception, DenseNet169, DenseNet201 ve ResNet152V2 yöntemlerinin doğruluk değerleri arasında istatistiksel olarak anlamlı bir farklılık bulunmamıştır ($p>0,05$).
7. Kron-kök veri setimizdeki orijinal ve ön işlemleri görüntüler derin öğrenme yöntemlerinin bütün kombinasyonları denenerek orijinal veri setinde en yüksek ortalama doğruluk değeri ResNet50V2, VGG16, InceptionV3, DenseNet169, ResNet152V2 derin öğrenme

mimarilerinin kombine kullanımıyla 0,885 (%88,5), ön işlemleri veri setinde ResNet50, InceptionV3, DenseNet169, ResNet152V2 derin öğrenme mimarilerinin kombine kullanımıyla 0,886 (%88,6) ve çoğunluk oylaması (majority voting) sonucu ResNet50V2 (orijinal görüntülerde), EfficientNetB0 (orijinal görüntülerde), InceptionV3 (ön işlem yapılmış görüntülerde), DenseNet169 (orijinal görüntülerde) ve ResNet152V2 (ön işlem yapılmış görüntülerde) derin öğrenme mimarilerinin kombine kullanımıyla 0,902 (%90,2) olarak bulunmuştur.

8. Kök veri setimizdeki orijinal ve ön işlemleri görüntüler derin öğrenme yöntemlerinin bütün kombinasyonları denenerek orijinal veri setinde en yüksek ortalama doğruluk değeri ResNet50V2, VGG16, VGG19, Xception, InceptionV3, DenseNet201, ResNet152V2 derin öğrenme mimarilerinin kombine kullanımı ile 0,892 (%89,2), ön işlemleri veri setinde ResNet50V2, VGG19, ResNet152V2 derin öğrenme mimarilerinin kombine kullanımıyla 0,887 (%88,7) ve çoğunluk oylaması (majority voting) sonucu ResNet50 (orijinal görüntülerde), ResNet50V2 (ön işlem yapılmış görüntülerde), VGG16 (ön işlem yapılmış görüntülerde), EfficientNetB1 (orijinal görüntülerde), InceptionV3 (orijinal görüntülerde), DenseNet169 (orijinal görüntülerde) ve DenseNet201 (ön işlem yapılmış görüntülerde) derin öğrenme mimarilerinin kombine kullanımıyla 0,897 (%89,7) olarak bulunmuştur.

9. Çalışmamızın sonuçlarına göre kron-kök grubunda doğruluk majority voting sonucunu veren kombine derin öğrenme yöntemlerinin kesinlik değeri 0,900, duyarlılık değeri 0,903, özgüllük değeri 0,901 ve F1 skoru 0,902 olarak bulunmuştur. Kök grubunda doğruluk majority voting sonucunu veren kombine derin öğrenme yöntemlerinin kesinlik değeri 0,912, duyarlılık değeri 0,885, özgüllük değeri 0,910 ve F1 skoru 0,898 olarak bulunmuştur.

10. Çalışmamızda veri ön işleme derin öğrenme yöntemlerinin ortalama doğruluk değerlerini anlamlı derecede artırmamış olup, bazı derin

öğrenme yöntemlerinde veri ön işleme sonucunda ortalama doğruluk değerlerinde düşüş gözlenmiştir.

11. Çalışmamızda ayrıca derin öğrenme yöntemlerinin hiyerarşik yapılarının farklılık göstermesinden dolayı, tek başına ve kombine kullanımlarında farklı performans sonuçları vermesi çoğunluk oylaması (majority voting) sonuçlarından anlaşılmaktadır.

Sonuç olarak bulgularımız göz önünde bulundurulduğunda, YZ algoritmalarının mandibular ikinci molar dişlerdeki C şekilli kanalları hem kron-kök grubunda hem de kök grubunda tespit etmede yeterli olduğu, ancak daha fazla veri ve ileri görüntü işleme yöntemleriyle eğitilerek çok merkezli çalışmalarla beraber daha da iyileştirilebileceğini söyleyebiliriz.

KAYNAKLAR

1. Manning SA. Root canal anatomy of mandibular second molars. *International Endodontic Journal*. 1990; 23(1): 40-45.
2. Jung HJ, Lee SS, Huh KH, Yi WJ, Heo MS, Choi SC. Predicting the configuration of a C-shaped canal system from panoramic radiographs. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology and Endodontology*. 2010; 109(1): e37-e41.
3. Miloğlu Ö, Yıldırım E, Ersoy İ, Akgül HM. Root morphology and C-shaped canal system in mandibular second molars on cone beam computed tomography images [Internet]. 2012. Available from: <https://dentistry-ataunipress.org>
4. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Science in Dentistry*. 2019; 49(1): 1.
5. Yang S, Lee H, Jang B, et al. Development and validation of a visually explainable deep learning model for classification of C-shaped canals of the mandibular second molars in periapical and panoramic dental radiographs. *Journal of Endodontics*. 2022; 48(7): 914-921.
6. Hudson DA Remeikis NA, Cura JE Van. Instrumentation of curved root canals: A comparison study. *Journal of Endodontics*. 1992; 18(9): 448-450.
7. Melton DC, Krell K V, Fuller MW. Anatomical and histological features of C-shaped canals in mandibular second molars. *Journal of Endodontics*. 1991; 17(8): 384-388.
8. Chai WL, Thong YL. Cross-sectional morphology and minimum canal wall widths in C-shaped roots of mandibular molars. *Journal of Endodontics*. 2004; 30(7): 509-512.
9. Rahimi S, Shahi S, Lotfi M, Zand V. Root canal configuration and the prevalence of C-shaped canals in mandibular second molars in an Iranian population. *Journal of Oral Science*. 2008; 50(1): 9-13.

10. Jafarzadeh H, Wu YN. The C-shaped root canal configuration: A review. *Journal of Endodontics*. 2007; 33(5): 517-523.
11. Trope M, Maltz D, Tronstad L. Resistance to fracture of restored endodontically treated teeth. *Dental Traumatology*. 1985; 1(3): 108-111.
12. Sert S, Bayirli G. Evaluation of the root canal configurations of the mandibular and maxillary permanent teeth by gender in the Turkish population. *Journal of Endodontics*. 2004; 30(6): 391-398.
13. Kato A, Ziegler A, Higuchi N, Nakata K, Nakamura H, Ohno N. Aetiology, incidence and morphology of the C-shaped root canal system and its impact on clinical endodontics. *International Endodontic Journal*. 2014; 47(11): 1012-1033.
14. Keith A, Knowles FH. A description of teeth of palaeolithic man from Jersey. *Journal of Anatomy and Physiology*. 1911.
15. Nakayama A. Gutter shaped root in human mandibular molars. *Kokubyo Gakkai Zasshi Japanese*. 1941; 15: 275-281.
16. Tratman EK. A comparison of the teeth of people; Indo-European racial stock with the Mongoloid racial stock. *Dental Record (London)*. 1950;70(3): 63-88.
17. Cooke HG, Cox FL. C-shaped canal configurations in mandibular molars. *The Journal of the American Dental Association*. 1979; 99(5): 836-839.
18. Barril I, Cochet JY, Ricci C. [Treatment of a canal with a “C” configuration]. *Rev Fr Endod*. 1989; 8(3): 47-58.
19. Fan B, Cheung G, Fan M, Gutmann J, Fan W. C-shaped canal system in mandibular second molars: part II—Radiographic features. *Journal of Endodontics*. 2004; 30(12): 904-908.
20. Helvacioğlu-Yigit D, Sinanoglu A. Use of cone-beam computed tomography to evaluate C-shaped root canal systems in mandibular second molars in a Turkish subpopulation: A retrospective study. *International Endodontic Journal*. 2013; 46(11): 1032-1038.

21. Fan B, Cheung G, Fan M, Gutmann J, Bian Z. C-shaped canal system in mandibular second molars: part I—Anatomical features. *Journal of Endodontics*. 2004; 30(12): 899-903.
22. Jerome CE. C-shaped root canal systems: diagnosis, treatment, and restoration. *Gen Dent*. 1994; 42(5): 424-427.
23. Bolger WL, Schindler WG. A mandibular first molar with a C-shaped root configuration. *Journal of Endodontics*. 1988; 14(10): 515-519.
24. Jin GC, Lee SJ, Roh BD. Anatomical study of C-shaped canals in mandibular second molars by analysis of computed tomography. *Journal of Endodontics*. 2006; 32(1): 10-13.
25. Seo MS, Park DS. C-shaped root canals of mandibular second molars in a Korean population: clinical observation and in vitro analysis. *International Endodontic Journal*. 2004; 37(2): 139-144.
26. Yang Z, Yang S, Lin Y, Shay J, Chi C. C-shaped root canals in mandibular second molars in a Chinese population. *Dental Traumatology*. 1988; 4(4): 160-163.
27. Haddad GY, Nehme WB, Ounsi HF. Diagnosis, classification, and frequency of C-shaped canals in mandibular second molars in the Lebanese population. *Journal of Endodontics*. 1999; 25(4): 268-271.
28. Lambrianidis T, Lyroudia K, Pandelidou O, Nicolaou A. Evaluation of periapical radiographs in the recognition of C-shaped mandibular second molars. *International Endodontic Journal*. 2001; 34(6): 458-462.
29. Sabala CL, Benenati FW, Neas BR. Bilateral root or root canal aberrations in a dental school patient population. *Journal of Endodontics*. 1994; 20(1): 38-42.
30. Robertson D, Leeb IJ, McKee M, Brewer E. A clearing technique for the study of root canal systems. *Journal of Endodontics*. 1980; 6(1): 421-424.
31. Weng XL, Yu S Bin, Zhao SL, et al. Root canal morphology of permanent maxillary teeth in the Han Nationality in Chinese Guanzhong Area: A new modified root canal staining technique. *Journal of Endodontics*. 2009; 35(5): 651-656.

32. Vertucci FJ. Root canal anatomy of the human permanent teeth. *Oral Surgery, Oral Medicine, Oral Pathology*. 1984; 58(5): 589-599.
33. Pineda F, Kuttler Y. Mesiodistal and buccolingual roentgenographic investigation of 7,275 root canals. *Oral Surgery, Oral Medicine, Oral Pathology*. 1972; 33(1): 101-110.
34. Gao Y, Fan B, Cheung GSP, Gutmann JL, Fan M. C-shaped canal system in mandibular second molars. part IV: 3-D morphological analysis and transverse measurement. *Journal of Endodontics*. 2006; 32(11): 1062-1065.
35. Solomonov M, Paqué F, Fan B, Eilat Y, Berman LH. The challenge of C-shaped canal systems: A comparative study of the self-adjusting file and protaper. *Journal of Endodontics*. 2012; 38(2): 209-214.
36. De Moor RJG. C-shaped root canal configuration in maxillary first molars. *International Endodontic Journal*. 2002; 35(2): 200-208.
37. He W, Wei K, Chen J, Yu Q. Endodontic treatment of maxillary first molars presenting with unusual asymmetric palatal root morphology using spiral computerized tomography: A case report. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology and Endodontology*. 2010; 109(1): e55-e59.
38. Malagnino V, Gallottini L, Passariello P. Some unusual clinical cases on root anatomy of permanent maxillary molars. *Journal of Endodontics*. 1997; 23(2): 127-128.
39. Dankner E, Friedman S, Stabholz A. Bilateral C shape configuration in maxillary first molars. *Journal of Endodontics*. 1990; 16(12): 601-603.
40. Fava LRG, Weinfeld I, Fabri FP, Pais CR. Four second molars with single roots and single canals in the same patient. *International Endodontic Journal*. 2000; 33(2): 138-142.
41. Grocholewicz K, Lipski M, Weyna E. Endodontic and prosthetic treatment of teeth with C-shaped root canals. *Annales Academiae Medicae Stetinensis*. 2009;55(3): 55-59.
42. Benenati FW. Mandibular second molar with C-shaped canal morphology and five canals: report of a case. *General Dentistry*. 2004; 52(3): 253-254.

43. Gulabivala K, Opasanon A, Ng Y-L., Alavi A. Root and canal morphology of Thai mandibular molars. *International Endodontic Journal*. 2002; 35(1): 56-62.
44. Barnett F. Mandibular molar with C-shaped canal. *Dental Traumatology*. 1986; 2(2): 79-81.
45. Xu X, Wang DG, Wang XY. Clinical significance of the abnormal radiographic manifestations of pulp cavity. *Shanghai Kou Qiang Yi Xue*. 1996; 5(2): 85-86.
46. Cohenca N, Simon JH, Roges R, Morag Y, Malfaz JM. Clinical indications for digital imaging in dento-alveolar trauma. part 1: Traumatic injuries. *Dental Traumatology*. 2007; 23(2): 95-104.
47. Cotton T, Geisler T, Holden D, Schwartz S, Schindler W. Endodontic applications of cone-beam volumetric tomography. *Journal of Endodontics*. 2007; 33(9): 1121-1132.
48. Exadaktylos AK, Sclabas GM, Smolka K, et al. The value of computed tomographic scanning in the diagnosis and management of orbital fractures associated with head trauma: A prospective, consecutive study at a level I trauma center. *The Journal of Trauma: Injury, Infection, and Critical Care*. 2005; 58(2): 336-341.
49. Grimard BA, Hoidal MJ, Mills MP, Mellonig JT, Nummikoski PV, Mealey BL. Comparison of clinical, periapical radiograph, and cone-beam volume tomography measurement techniques for assessing bone level changes following regenerative periodontal therapy. *Journal of Periodontology*. 2009; 80(1): 48-55.
50. Mora MA, Mol A, Tyndall DA, Rivera EM. In vitro assessment of local computed tomography for the detection of longitudinal tooth fractures. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*. 2007; 103(6): 825-829.
51. Heithersay GS. Clinical endodontic and surgical management of tooth and associated bone resorption. *International Endodontic Journal*. 1985; 18(2): 72-92.
52. Whaites E. *Essentials of dental radiography and radiology*.

53. Harorlı A, Akgül HM, Dağıstan S. Diş hekimliği radyolojisi. Eser Ofset Matbaacılık, 2006.
54. Özcan İ. Diş hekimliğinde radyolojinin esasları: konvansiyonelden dijital İstanbul Aydın Üniversitesi Bilgi Merkezi 2017 [Internet]. Available <https://www.nobelkitabevi.com.tr/dis-hekimligi-kitaplari/13266-dis-hekimliginde-radyolojinin-esaslari-9786059528108.html>
55. White SC, Pharoah MJ. Oral radiology: principles and interpretation, seventh edition. Elsevier; 2013 [Internet]. Available from: <http://www.sciencedirect.com:5070/book/9780323096331/oral-radiology>
56. Güniz Akdeniz B. Modern görüntüleme yöntemleri (I) Modern Imaging Modalities (I). 2000; Vol 2.
57. MacDonald D. Oral & maxillofacial radiology. 2011.
58. Tyndall DA, Rathore S. Cone-beam CT diagnostic applications: caries, periodontal bone assessment, and endodontic applications. Dental Clinics of North America. 2008; 52(4): 825-841.
59. Aydın U, Görmez O, Yildirim D. Cone-beam computed tomography imaging of dentoalveolar and mandibular fractures. Oral Radiology. 2020; 36(3): 217-224.
60. Chartrand G, Cheng PM, Vorontsov E, et al. Deep learning: A primer for radiologists. RadioGraphics. 2017; 37(7): 2113-2131.
61. Miladinović M, Mihailović B, Mladenović D, et al. Artificial intelligence in clinical medicine and dentistry. Vojnosanitetski Pregled. 2017; 74(3): 267-272
62. Haenlein M, Kaplan A. A brief history of artificial intelligence: on the past, present, and future of artificial intelligence. California Management Review. 2019; 61(4): 5-14.
63. Muggleton S. Alan Turing and the development of artificial intelligence. AI Communications. 2014; 27(1): 3-10.

64. Sunali D, Khanna S, Dhaimade PA, Khanna S. Artificial intelligence: transforming dentistry today. *Indian Journal of Basic and Applied Medical Research*. 2017; (6): 161-167.
65. Park WJ, Park JB. History and application of artificial neural networks in dentistry. *European Journal of Dentistry*. 2018; 12(4): 594.
66. Khanagar SB, Al-ehaideb A, Maganur PC, et al. Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *Journal of Dentistry Sciences*. 2021; 16(1): 508-522.
67. Hassabis D. Artificial intelligence: chess match of the century. *Nature*. 2017; 544(7651): 413-414.
68. Russell R. Machine learning step-by-step guide to implement machine learning algorithms with python. 2018: 106.
69. Pannu A, Student MT. Artificial intelligence and its application in different areas. *International Journal of Engineering and Innovative Technology (IJEIT)*. Vol 4.; 2015.
70. Bahrammirzaee A. A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Computing and Applications*. 2010; 19(8): 1165-1195.
71. Alpaydın E. Yapay öğrenme: yeni yapay zekâ. *Türkmenler Matbaacılık* 2022 [Internet]. Available from: <https://www.simurgkitabevi.com>
72. Warwick K. Artificial intelligence: the basics. Routledge; 2012 [Internet]. Available from: <https://www.routledge.com>
73. Michalewicz Z, Schoenauer M. Evolutionary algorithms for constrained parameter optimization problems. *Evolutionary Computation*. 1996; 4(1): 1-32.
74. Fulcher J. Advances in applied artificial intelligence. *Advances in Applied Artificial Intelligence*. 2006: 1-309.
75. Mathew TV. Genetic algorithm. *Indian Institute of Technology Bombay, Mumbai*. 2012.

76. Lam HK, Ling SH, Leung FHF, Tam PKS. Tuning of the structure and parameters of neural network using an improved genetic algorithm. In: IECON'01. 27th Annual Conference of the IEEE Industrial Electronics Society (Cat. No.37243). IEEE: 25-30.
77. İsmail D, Altaş H. Bulanık mantık: bulanıklılık kavramı. Enerji, Elektrik, Elektromekanik. Vol 62; 1999.
78. Nabiye VV. Yapay zekâ: insan-bilgisayar etkileşimi. 5. Baskı. Ankara; Seçkin Yayıncılık San. ve Tic. A.Ş. 2010 [Internet]. Available from: <https://www.nadirkitap.com>
79. El Hatri C, Boumhidi J. Fuzzy deep learning based urban traffic incident detection. Cognitive Systems Research. 2018; 50: 206-213.
80. Hasan Sapci A, Aylin Sapci H. Artificial intelligence education and tools for medical and health informatics students: systematic Review. JMIR Medical Education. 2020; 6(1).
81. Zhang X Da. A matrix algebra approach to artificial intelligence. 2020: 1-805.
82. Johnson KW, Torres Soto J, Glicksberg BS, et al. Artificial intelligence in cardiology. Journal of the American College of Cardiology. 2018; 71(23): 2668-2679.
83. Lecun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015; 521:7553: 436-444.
84. Fyfe C. Artificial neural networks and information theory. 2000.
85. Hamet P, Tremblay J. Artificial intelligence in medicine. Metabolism. 2017; 69: S36-S40.
86. Ng A. Generative learning algorithms. 2008.
87. Yılmaz A. Yapay zekâ. 7. Baskı. İnkılap Kitabevi Yayın San. Tic. A.Ş. 2020 [Internet]. Available from: <https://www.inkilap.com>
88. Raschka S, Mirjalili V. Python machine learning: machine learning and deep learning with python, scikit-learn, and tensorflow. Packt Publishing; 2017.

89. Deng L, Yu D. Deep learning: methods and applications. *Foundations and Trends in Signal Processing*. 2013; 7(3-4): 197-387.
90. Ahmad I, Basher M, Iqbal MJ, Rahim A. Performance comparison of support vector machine, random forest, and extreme learning machine for intrusion detection. *IEEE Access*. 2018; 6: 33789-33795.
91. Huang S, Nianguang CAI, Penzuti Pacheco P, Narandes S, Wang Y, Wayne XU. Applications of support vector machine (SVM) learning in cancer genomics. *Cancer Genomics Proteomics*. 2018; 15(1): 41.
92. Chermiti B. Establishing risk and targeting profiles using data mining: decision trees. *World Customs Journal*. Vol 13. 2019.
93. Song YY, Lu Y. Decision tree methods: applications for classification and prediction. *Shanghai Archive Psychiatry*. 2015; 27(2): 130-135.
94. Myles AJ, Feudale RN, Liu Y, Woody NA, Brown SD. An introduction to decision tree modeling. *Journal of Chemometrics*. 2004; 18(6): 275-285.
95. Salmani F, Taheri SM, Yoon JH, Abadi A, Alavi Majd H, Abbaszadeh A. Logistic regression for fuzzy covariates: modeling, inference, and applications. *International Journal of Fuzzy Systems*. 2017; 19(5): 1635-1644.
96. Christodoulou E, Ma J, Collins GS, Steyerberg EW, Verbakel JY, Van Calster B. A systematic review shows no performance benefit of machine learning over logistic regression for clinical prediction models. *Journal of Clinical Epidemiology*. 2019; 110: 12-22.
97. Namdari M, Abadi A, Taheri SM, Rezaei M, Kalantari N, Omidvar N. Effect of folic acid on appetite in children: ordinal logistic and fuzzy logistic regressions. *Nutrition*. 2014; 30(3): 274-278.
98. Sydenham PH, Thorn R. *Handbook of measuring system design*. Wiley; 2005.
99. Hamzaçebi Ç. *Yapay sinir ağları*. Ekin Yayınevi, Bursa, 2011.
100. Heaton J. *Artificial intelligence for humans*. 2013.

101. Yasav M. Yapay Sinir Ağlarıyla Yüz Mimiklerinin Tanınması. Yüksek lisans tezi. Yıldız Teknik Üniversitesi Elektronik Haberleşme Mühendisliği Anabilim Dalı 2008.
102. İnik Ö, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 2017; 6.3: 85-104.
103. Goodfellow I, Bengio Y, Courville A. Deep learning 2016 [Internet]. Available from: <https://www.deeplearningbook.org>
104. Marcus G. Deep learning: A critical appraisal. archive preprint archive: 2018: 1801.00631.
105. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting. Journal of Machine Learning Research. 2014; 15(56): 1929-1958.
106. Tamura S, Tateishi M. Capabilities of a four-layered feedforward neural network: four layers versus three. IEEE Transactions Neural Networks. 1997; 8(2): 251-255.
107. Ciresan Dan C, Meier U, Masci J, Gambardella LM, Urgan Schmidhuber J. Flexible, high performance convolutional neural networks for image classification. Proceedings of the 22nd International Joint Conference on Artificial Intelligence. 2011.
108. Hinton GE. A practical guide to training restricted boltzmann machines. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). 2012; 7700 LECTURE NO: 599-619.
109. Li H, Lin Z, Shen X. A convolutional neural network cascade for face detection. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 5325-5334.
110. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks 2012 [Internet]. Available from: <http://code.google.com/p/cuda-convnet/>

111. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [Internet]. 2023. Available from: <https://www.researchgate.net>
112. Zeiler MD, Fergus R. Visualizing and understanding convolutional networks. 2013.
113. Russakovsky O, Deng J, Su H. ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*. 2015; 115(3): 211-252.
114. Fukuda M, Inamoto K, Shibata N, et al. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiology*. 2020; 36(4): 337-343.
115. Shi S, Wang Q, Xu P et al. Benchmarking state-of-the-art deep learning software tools. In: 2016 7th International Conference on Cloud Computing and Big Data (CCBD). IEEE, 2016: 99-104.
116. Al-Rfou R, Alain G, et al. Theano: A Python framework for fast computation of mathematical expressions [Internet]. 2016. Available from: <http://arxiv.org/abs/1605.02688>
117. Sunali D, Khanna S, Dhaimade PA, Khanna S. Artificial intelligence: transforming dentistry today. *Indian Journal of Basic and Applied Medical Research*. 2017; (6): 161-167.
118. Tandon D, Rajawat J. Present and future of artificial intelligence in dentistry. *Journal of Oral Biology Craniofacial Research*. 2020; 10(4): 391.
119. Devito KL, de Souza Barbosa F, Filho WNF. An artificial multilayer perceptron neural network for diagnosis of proximal dental caries. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology and Endodontology*. 2008; 106(6): 879-884.
120. Valizadeh S, Goodini M, Ehsani S, Mohseni H, Azimi F, Bakhshandeh H. Designing of a computer software for detection of approximal caries in posterior teeth. *Iranian Journal of Radiology*. 2015; 12(4): 16242.

121. Görler O, Akkoyun S. Artificial neural networks can be used as alternative method to estimate loss tooth root sizes for prediction of dental implants. *Cumhuriyet Science Journal*. 2017; 38(2): 385-385.
122. Grischke J, Johannsmeier L, Eich L, Griga L, Haddadin S. Dentronics: towards robotics and artificial intelligence in dentistry. *Dental Materials*. 2020; 36(6): 765-778.
123. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Science in Dentistry*. 2019; 49(1): 1.
124. Corbella S, Srinivas S, Cabitza F. Applications of deep learning in dentistry. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*. 2021; 132(2): 225-238.
125. Jeon SJ, Yun JP, Yeom HG, et al. Deep-learning for predicting C-shaped canals in mandibular second molars on panoramic radiographs. *Dentomaxillofacial Radiology*. 2021; 50(5): 20200513.
126. Zhang L, Xu F, Li Y, et al. A lightweight convolutional neural network model with receptive field block for C-shaped root canal detection in mandibular second molars. *Scientific Reports*. 2022; 12(1): 1-11.
127. Yang S, Lee H, Jang B, et al. Development and validation of a visually explainable deep learning model for classification of C-shaped canals of the mandibular second molars in periapical and panoramic dental radiographs. *Journal of Endodontics*. 2022; 48(7): 914-921.
128. Sherwood AA, Sherwood AI, Setzer FC, et al. A deep learning approach to segment and classify C-shaped canal morphologies in mandibular second molars using cone-beam computed tomography. *Journal of Endodontics*. 2021; 47(12): 1907-1916.
129. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition 2015 [Internet]. Available from: <http://image-net.org/challenges/LSVRC/2015/>
130. Szegedy C, Vanhoucke V, Ioffe S, Shlens J. Rethinking the inception architecture for computer vision. Published in *Computer Vision and Pattern Recognition*. 2015.

131. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition 2014 [Internet]. Available from: <http://arxiv.org/abs/1409.1556>
132. Tan M, Le Q V. EfficientNet: Rethinking model scaling for convolutional neural networks 2019 [Internet]. Available from: <http://arxiv.org/abs/1905.11946>
133. Alkhadar H, Macluskey M, White S, Ellis I, Gardner A. Comparison of machine learning algorithms for the prediction of five-year survival in oral squamous cell carcinoma. *Journal of Oral Pathology & Medicine*. 2021; 50(4): 378-384.
134. Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks 2017 [Internet]. Available from: <https://github.com/liuzhuang13/DenseNet>.
135. Yu T, Zhu H. Hyper-parameter optimization: A review of algorithms and applications 2020 [Internet]. Available from: <http://arxiv.org/abs/2003.05689>
136. Mayo CV, Montgomery S, Rio C Del. Scientific articles a computerized method for evaluating root canal morphology. *Journal of Endodontics*. 1986; 12(1): 2-7.
137. Gulabivala K, Aung TH, Alavi A, Ng YL. Root and canal morphology of Burmese mandibular molars. *International Endodontic Journal*. 2001; Vol 34(5): 359-370
138. Omer OE, Al Shalabi RM, Jennings M, Glennon J, Claffey NM. A comparison between clearing and radiographic techniques in the study of the root-canal anatomy of maxillary first and second molars. *International Endodontic Journal*. 2004; 37(5): 291-296
139. Skidmore AE, Bjorndal AI. Root canal morphology of the human mandibular first molar. *Oral Surgery, Oral Medicine, Oral Pathology*. 1971; 32(5): 778-784
140. Weine FS, Pasiewicz RA, Rice RT. Canal configuration of the mandibular second molar using a clinically oriented in vitro method. Vol 14. *Journal of Endodontics*. 1988; 14(5): 207-213

141. Fan W, Fan B, Gutmann JL, Cheung GSP. Identification of C-shaped canal in mandibular second molars. part I: Radiographic and anatomical features revealed by intraradicular contrast medium. *Journal of Endodontics*. 2007; 33(7): 806-810.
142. Kottoor J, Nandini S, Velmurugan N. Maxillary first molar with three buccal roots evaluated with cone-beam computed tomography: A rare case report. *General Dentistry*. 2012; 60(6): e404-e407.
143. Kim Y, Lee SJ, Woo J. Morphology of maxillary first and second molars analyzed by cone-beam computed tomography in a Korean population: variations in the number of roots and canals and the incidence of fusion. *Journal of Endodontics*. 2012; 38(8): 1063-1068.
144. Zheng Q, Zhang L, Zhou X, et al. C-shaped root canal system in mandibular second molars in a Chinese population evaluated by cone-beam computed tomography. *International Endodontic Journal*. 2011; 44(9): 857-862.
145. Jin GC, Lee SJ, Roh BD. Anatomical study of C-shaped canals in mandibular second molars by analysis of computed tomography. *Journal of Endodontics*. 2006; 32(1): 10-13.
146. Chai WL, Thong YL. Cross-sectional morphology and minimum canal wall widths in C-shaped roots of mandibular molars. *Journal of Endodontics*. 2004; Vol 30(7): 509-512.
147. Jung HJ, Lee SS, Huh KH, Yi WJ, Heo MS, Choi SC. Predicting the configuration of a C-shaped canal system from panoramic radiographs. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology and Endodontology*. 2010; 109(1): e37-e41.
148. Arslan ZB, Doğan FB, İçöz D. Evaluation of the prevalence of C-shaped canal configuration in mandibular first and second molar teeth with cone beam computed tomography in the Turkish subpopulation: A retrospective study. *Türkiye Klinikleri Journal of Dental Sciences*. 2024; 30(1): 23-30.
149. Aslan E, Ulusoy AC, Baksı BG, Mert A, Şen BH. Cone beam computed tomography evaluation of C-shaped canal morphology in mandibular premolar teeth. *European Oral Research*. 2024; 58(2): 70-75.

150. Min Y, Fan B, Cheung G, Gutmann J, Fan M. C-shaped canal system in mandibular second molars. part III: the morphology of the pulp chamber floor. *Journal of Endodontics*. 2006; 32(12): 1155-1159.
151. Krasner P, Rankow HJ. Anatomy of the pulp-chamber floor. *Journal of Endodontics*. 2003; 30(1): 5-16.
152. 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. *Dentomaxillofacial Radiology*. 2019; 49(1).
153. Shan T, Tay FR, Gu L. Application of artificial intelligence in dentistry. *Journal of Dental Research*. 2021; 100(3): 232-244.
154. Abdulkadir Ş. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*. Vol 3; 2017.
155. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nature Reviews Cancer*. 2018; 18(8): 500-510.
156. Thrall JH, Li X, Li Q, et al. Artificial intelligence and machine learning in radiology: opportunities, challenges, pitfalls, and criteria for success. *Journal of the American College of Radiology*. 2018; 15(3): 504-508.
157. Hiraiwa T, Arijji Y, Fukuda M, et al. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofacial Radiology*. 2019; 48(3): 20180218.
158. Yang S, Kim KD, Kise Y, et al. External validation of the effect of the combined use of object detection for the classification of the C-shaped canal configuration of the mandibular second molar in panoramic radiographs: A multicenter study. *Journal of Endodontics*. 2024; 50(5): 627-636.
159. Yang S, Kim KD, Arijji E, Takata N, Kise Y. Evaluating the performance of generative adversarial network-synthesized periapical images in classifying C-shaped root canals. *Scientific Reports*. 2023; 13(1): 18038.
160. Moon JH, Hwang HW, Yu Y, Kim MG, Donatelli RE, Lee SJ. How much deep learning is enough for automatic identification to be reliable? A cephalometric example. *The Angle Orthodontist*. 2020; 90(6): 823-830.

161. Oktay AB. Tooth detection with convolutional neural networks. In: 2017 Medical Technologies National Conference, TIPTEKNO 2017; Vol: 1-4.
162. Poonsri A, Aimjirakul N, Charoenpong T, and Sukjamsri C. “Teeth Segmentation from Dental x-Ray Image by Template Matching”, In 2016 9th Biomedical Engineering International Conference (BMEiCON). 2016 Pp. 1-4.
163. Leite AF, Gerven A Van, Willems H. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clinical Oral Investigations*. 2020; 25(9): 1-11.
164. Silva G, Oliveira L, Pithon M. Automatic segmenting teeth in X-ray images: trends, a novel data set, benchmarking and future perspectives. *Expert Systems with Applications*. 2018; 107: 15-31.
165. Chen Q, Huang J, Salehi HS, et al. Hierarchical CNN-based occlusal surface morphology analysis for classifying posterior tooth type using augmented images from 3D dental surface models. *Computer Methods and Programs in Biomedicine*. 2021; 208, 106295.

EKLER

Ek 1. ETİK KURUL ONAY FORMU

Evrak Tarih ve Sayısı: 05.04.2023-E.353313



T.C.
PAMUKKALE ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu

Sayı : E-60116787-020-353313
Konu : Başvurunuz Hk.

05.04.2023

Sayın Prof. Dr. Hayati Murat AKGÜL

İlgi : 06/03/2023 tarihli dilekçeniz. 192.168.202.47
96491
8.10.2024

İlgi dilekçe ile başvurmuş olduğunuz "Konik Işınlı Bilgisayarlı Tomografi İle Tespit Edilen Mandibular İkinci Molarlardaki C Şekilli Kanalların Panoramik Radyograflar Üzerinde Tespit Edilme Etkinliğinin Yapay Zekâ Modeli Üzerinde Değerlendirilmesi" konulu çalışmanız 04.04.2023 tarih ve 06 sayılı kurul toplantımızda görüşülmüş olup,

Yapılan görüşmelerden sonra; söz konusu çalışmanın yapılmasında ETİK AÇIDAN SAKINCA OLMADIĞINA, altı ayda bir çalışma hakkında Kurulumuza bilgi verilmesine oy birliği ile karar verilmiştir.

Bilgilerinizi rica ederim.

Prof. Dr. Hülya ÇETİN
Kurul Başkanı

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu :BSEAH52989 Pin Kodu :93962

Belge Takip Adresi : <https://www.turkiye.gov.tr/pau-ethys>

Adres: Tıp Fakültesi Dekanlığı Kınıklı/Denizli

Telefon: 0 (025) 8 Faks: 0 (258) 296 17 65

e-Posta: tibbiestetik@pau.edu.tr Elektronik Ağ: <http://www.pau.edu.tr>

Kep Adresi: paurektortuk@hs01.kep.tr

Bilgi için: Selda ERKİŞİ
Unvanı: Bilgisayar İşletmeni



Bu belge, güvenli elektronik imza ile imzalanmıştır.

Ek 2. ÖZGEÇMİŞ

Kişisel Bilgiler

Adı	Ozan	Uyruğu	T.C.
Soyadı	UYSAL	Tel no	
Doğum tarihi		e-posta	

Eğitim Bilgileri

Mezun olduğu kurum		Mezuniyet yılı
Lise	Manavgat Anadolu Lisesi	2013
Lisans/Yüksek Lisans	Süleyman Demirel Üniversitesi	2019

İş Deneyimi

Görevi	Kurum	Süre (Yıl-Yıl)
Araştırma Görevlisi	Pamukkale Üniversitesi Diş Hekimliği Fakültesi	2021-halen

Yabancı Dilleri	Sınav türü	Puanı
İngilizce	YÖKDİL	60

