



**T.C.
GAZİ ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ**

**UZMANLIK
TEZİ**

**YETİŞKİN BİREYLERDE PANORAMİK RADYOGRAFI
GÖRÜNTÜLERİ KULLANILARAK YAŞIN
BELİRLENMESİNDE DERİN ÖĞRENME MODELİ**

ÇAĞRI ERDOĞDU

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

EYLÜL 2025



**YETİŞKİN BİREYLERDE PANORAMİK RADYOGRAFİ GÖRÜNTÜLERİ
KULLANILARAK YAŞIN BELİRLENMESİNDE DERİN ÖĞRENME
MODELİ**

Çağrı ERDOĞDU

UZMANLIK TEZİ

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

GAZİ ÜNİVERSİTESİ

DİŞ HEKİMLİĞİ FAKÜLTESİ

Eylül 2025

Çağrı ERDOĞDU tarafından hazırlanan “Yetişkin Bireylerde Panoramik Radyografi Görüntüleri Kullanılarak Yaşın Belirlenmesinde Derin Öğrenme Modeli” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ / OY ÇOKLUĞU ile Gazi Üniversitesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalında UZMANLIK TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Gülsün Akay

Ağız, Diş ve Çene Radyolojisi Anabilim, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Uzmanlık Tezi olduğunu onaylıyorum/onaylamıyorum

Başkan: Prof. Dr. Kahraman Güngör

Ağız, Diş ve Çene Radyolojisi Anabilim, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Uzmanlık Tezi olduğunu onaylıyorum/onaylamıyorum

Üye: Dr. Öğr. Üyesi Hatice Boyacıoğlu Erden

Ağız, Diş ve Çene Radyolojisi Anabilim, Hacettepe Üniversitesi

Bu tezin, kapsam ve kalite olarak Uzmanlık Tezi olduğunu onaylıyorum/onaylamıyorum

Tez Savunma Tarihi:/...../.....

Jüri tarafından kabul edilen bu tezin Uzmanlık Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Kahraman Güngör

Diş Hekimliği Fakültesi Dekanı

ETİK BEYAN

Gazi Üniversitesi Sağlık Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Çağrı ERDOĞDU

08/09/2025

YETİŞKİN BİREYLERDE PANORAMİK RADYOGRAFİ GÖRÜNTÜLERİ
KULLANILARAK YAŞIN BELİRLENMESİNDE DERİN ÖĞRENME MODELİ

(Uzmanlık Tezi)

Dt. Çağrı ERDOĞDU

GAZİ ÜNİVERSİTESİ

DİŞ HEKİMLİĞİ FAKÜLTESİ

EYLÜL 2025

ÖZET

Dişler, dayanıklı yapıları ve yaşam boyu gösterdikleri değişimler nedeniyle yaş tahmini için kullanımları güvenilir kabul edilen biyolojik göstergelerdir. Yetişkin bireylerde yaş tayini, diş gelişiminin tamamlanmış olması nedeniyle çocuklara kıyasla daha karmaşık olup, sekonder dentin birikimi ve pulpa boşluğundaki değişim gibi ince morfolojik göstergelerin değerlendirilmesini gerektirir. Veri işleme teknolojilerinin gelişimi ile birlikte yapay zeka uygulamaları giderek yaygınlaşmaktadır. Bu gelişmeler, medikal alanda tanı, tedavi ve prognostik değerlendirme gibi birçok süreçte yapay zekanın kullanımını mümkün kılmaktadır. Bu tez çalışmasında, yetişkin popülasyonda panoramik radyografik görüntüler kullanılarak kronolojik yaş tahmininde derin öğrenme tabanlı modellerin etkinliği araştırılmıştır. Çalışma kapsamında, Gazi Üniversitesi Diş Hekimliği Fakültesi radyoloji arşivinden elde edilen 18-65 yaş aralığındaki 1920 adet yetişkin bireye ait panoramik radyografi görüntüsü kullanılmış olup hastaların kronolojik yaşı ve cinsiyet bilgileri etiketlenerek kodlanmıştır. Görüntüler veri ön işleme adımlarından geçirilerek EfficientNetB7, DenseNet201, InceptionV3 ve ResNet50V2 modelleri ile analiz edilmiştir. Modeller, yaş tahmini için regresyon yaklaşımıyla eğitilmiş ve performansları ortalama karesel hata (MSE), kök ortalama karesel hata (RMSE), mutlak ortalama hata (MAE) ve açıklayıcılık katsayısı (R^2) değerleri ile değerlendirilmiştir. Elde edilen sonuçlara göre EfficientNetB7 mimarisinin 3,813 yıl ile en düşük MAE'ye ve $R^2=0,908$ ile en yüksek açıklayıcılık katsayısı skoruna ulaştığı gözlemlendi. Sonuç olarak, çalışmamızda EfficientNetB7 modeli ile diğer modellere göre en iyi performans gösterdiği ve derin öğrenme tabanlı modellerin, panoramik radyograflardan yaş tahmini alanında yüksek doğruluk sağlayabileceği gösterilmiştir.

Bilim Kodu : 1044

Anahtar Kelimeler : Dental Yaş, yaş tahmini, yapay zeka, derin öğrenme, panoramik radyografi

Sayfa Adedi : 83

Danışman : Doç. Dr. Gülsün AKAY

DEEP LEARNING MODEL FOR AGE ESTIMATION USING PANORAMIC
RADIOGRAPHIC IMAGES IN ADULTS

(Speciality Thesis)

Dt. Çağrı ERDOĞDU

GAZI UNIVERSITY

FACULTY OF DENTISTRY

SEPTEMBER 2025

ABSTRACT

Teeth are considered reliable biological indicators for age estimation due to their durable structure and the changes they undergo throughout life. In adults, age determination is more complex than in children because tooth development is complete, requiring the evaluation of subtle morphological indicators such as secondary dentin accumulation and changes in the pulp cavity. With the advancement of data processing technologies, artificial intelligence (AI) applications are becoming increasingly widespread. These developments enable the use of AI in many medical processes, including diagnosis, treatment, and prognostic evaluation. In this thesis, the efficacy of deep learning-based models for chronological age estimation in an adult population using panoramic radiographic images was investigated. The study utilized 1920 panoramic radiographs of adults aged 18-65 years, which were obtained from the radiology archives of Gazi University Faculty of Dentistry. The chronological age and gender information of the patients were labeled and coded. The images were pre-processed and then analyzed using EfficientNetB7, DenseNet201, InceptionV3, and ResNet50V2 models. The models were trained with a regression approach for age estimation, and their performance was evaluated using the Mean Squared Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and the coefficient of determination (R^2) values. The results showed that the EfficientNetB7 architecture achieved the lowest MAE of 3.813 years and the highest coefficient of determination score of $R^2=0.908$. In conclusion, the EfficientNetB7 model outperformed the other models in our study, and deep learning-based models were found to provide high accuracy in the field of age estimation from panoramic radiographs.

Science Code : 1044

Key Words : Dental age, age estimation, artificial intelligence, deep learning,
panoramic radiograph

Page Number : 83

Supervisor : Associate Prof. Gülsün AKAY

TEŞEKKÜR

Uzmanlık eğitimim boyunca, her zaman yol göstericim olan, yoğun çalışma programı içerisinde daima bana vakit ayırarak bilimsel katkılarını ve desteğini esirgemeyen, enerjisi ve motivasyonu bana güç veren, akademik duruşu ve bilgisiyle örnek aldığım ve göstermiş olduğu hoşgörü, sabır ve anlayış için değerli danışman hocam Sayın Doç. Dr. Gülsün AKAY' a,

Çalışmalarında bilgi ve deneyimlerini hiçbir zaman esirgemeyen Fakülte Dekanımız Sayın Prof. Dr. Kahraman GÜNGÖR'e,

Bu Tez Çalışmasının gerçekleştirilmesinde değerli bilgi ve tecrübeleriyle katkı sağlayan, teknik konulardaki yönlendirmeleri ve yapıcı önerileriyle bana yol gösteren Gazi Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü'nden Sayın Prof. Dr. M. Ali AKCAYOL'a ve Munzur Üniversitesi Bilgisayar Mühendisliği Bölümü'nden Sayın Doç. Dr. Anıl Utku'ya,

Uzmanlık eğitim sürecimde bana hem hocalık hem de ablalık yapan Sayın Dr. Öğr. Üyesi Nebiha Gözde İSPİR ve Sayın Dr. Öğr. Üyesi Nuray BAĞCI'ya,

Bölümümüzün diğer öğretim üyeleri, Sayın Prof. Dr. Cemile Özlem ÜÇOK, Sayın Prof. Dr. Meryem TORAMAN, Sayın Prof. Dr. İlkay PEKER, Prof. Dr. Zühre ZAFERSON AKARSLAN ve Sayın Doç. Dr. Umut Pamukçu'ya

İlk günden itibaren, her zaman yanımda olan, dostluğu ve desteğiyle bu süreci daha kolay ve anlamlı hale getiren değerli meslektaşım ve eş kıdemlim Dt. Seda KAN'a,

Hayatımın her aşamasında yanımda olan, sabırları ve sevgileriyle beni daima destekleyen aileme en derin teşekkürlerimi sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
RESİMLERİN LİSTESİ	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ	1
2. GENEL BİLGİLER	3
2.1. Adli Bilimler ve Adli Dış Hekimliği	3
2.2. Adli Kimliklendirme	3
2.3. Kronolojik Yaş ve Biyolojik Yaş	4
2.4. Dental Yaş Belirleme.....	5
2.4.1. Çocuklarda yaş belirleme	6
2.4.2. Yetişkinlerde yaş belirleme yöntemleri	7
2.4.3. Yetişkinlerde radyografik yaş belirleme yöntemleri.....	9
2.5. Yaş Tayininde Kullanılan Radyolojik Yöntemler.....	11
2.5.1. Periapikal radyografi	11
2.5.2. Panoramik radyografi	11
2.5.3. Konik ışınlı bilgisayarlı tomografi	11
2.5.4. Mikro- bilgisayarlı tomografi (Mikro- BT)	12
2.5.5. Manyetik rezonans görüntüleme	12
2.6. Yapay Zeka.....	13
2.6.1. Yapay zeka nedir?	13
2.6.2. Makine öğrenmesi	14
2.6.3. Yapay sinir ağları	15
2.7. Derin Öğrenme	17
2.7.1. Evrişimli sinir ağları (Convolutional neural network)	18
2.7.2. Evrişimli sinir ağının katmanları	19

2.7.3. Evrişimli sinir ağlarının eğitimi.....	21
2.8. Derin Öğrenme Kütüphaneleri	21
2.8.1. PyTorch.....	22
2.8.2. OpenCV	22
2.8.3. TensorFlow	22
2.8.4. Keras.....	22
2.8.5. Caffe	23
2.9. Medikal Alanda Yapay Zeka Uygulamaları	23
2.9.1. Diş hekimliğinde yapay zeka uygulamaları.....	24
3. Gereç ve Yöntem	26
3.1. Hasta Seçimi.....	26
3.2. Görüntüleme Protokolü	27
3.3. Veri Setinin Oluşturulması ve Etiketlenmesi	27
3.4. Veri Ön İşleme ve Model Hazırlığı	30
3.5. Tahmin Modelleri	30
3.5.1. MobileNetV3	30
3.5.2 ResNet50	31
3.5.3 DenseNet121	31
3.5.4 EfficientNetB7	32
3.6. Karşılaştırmalı Model Analizi ve Hiperparametre Optimizasyonu.....	32
3.7. Model Performansının Değerlendirilmesi	34
3.8. Performans Değerlendirme Ölçütleri	35
4. Bulgular.....	38
5. Tartışma.....	45
5.1. Makine Öğrenmesine Yönelik Çalışmalar	47
5.2. Makine Öğrenme ve Derin Öğrenme Hibrit Çalışma	49
5.3. Derin Öğrenme Modelleri ile Yapılan Çalışmalar.....	49
6. Sonuç ve Öneriler	64
KAYNAKLAR.....	66
EKLER.....	81
EK-1. Etik Kurul Onayı	81
ÖZGEÇMİŞ	82

ÇİZELGELERİN LİSTESİ

Çizelge 3.1. Kullanılan Derin Öğrenme Modellerine Ait Hiperparametre Değerleri.....	33
Çizelge 4.1. Çalışma grubunun yaş-cinsiyet dağılımı	38
Çizelge 4.2. Farklı Modellerin Performans Karşılaştırması	39



ŞEKİLLERİN LİSTESİ

Şekil 2.1. Makine öğrenmesinin temel türleri ve görevleri	15
Şekil 2.2. Yapay sinir ağı şeması.....	17
Şekil 2.3: Yapay zekanın temel bileşenleri	18
Şekil 2.4. Evrişimli sinir ağı diyagramı	20
Şekil 3.1. Geliştirilen Sisteme Ait Akış Diyagramı	34
Şekil 4.1. MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modellerinin yaş tahmini problemine yönelik karşılaştırmalı MSE sonuçları	40
Şekil 4.2. MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modellerinin yaş tahmini problemine yönelik karşılaştırmalı RMSE sonuçları.....	40
Şekil 4.3. MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modellerinin yaş tahmini problemine yönelik karşılaştırmalı MAE sonuçları.....	41
Şekil 4.4. MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modellerinin yaş tahmini problemine yönelik karşılaştırmalı R^2 sonuçları.....	41
Şekil 4.5. Değerlendirilen modellere ait tahmin ve gerçek yaş arasındaki ilişkiyi gösteren grafik.....	42

RESİMLERİN LİSTESİ

Resim 3.1. Ham panoramik radyografi görüntüsü (A); diş arklarını ve çene kemiklerini içeren, modele girdi olarak kullanılan standart boyutta kırpılmış versiyonu (B).	28
Resim 3.2. Veri kümesinde kullanılan etiketlenmiş görsellere örnekler.....	29
Resim 4.1. En başarılı model olan EfficientNetB7'nin yaş tahminlerinde en düşük ve en yüksek hataya sahip olduğu örnek panoramik radyografi görüntüleri.....	43



SİMGELER VE KISALTMALAR

Simgeler	Açıklamalar
X^n	Giriş sinyali
W^n	Ağırlık katsayısı
n	Veri noktalarının sayısını ifade eder.
Y_i	i. veri noktasına ait gerçek (gözlemlenen) değeri temsil eder.
$\hat{Y}_i$	i. veri noktasına ait tahmin edilen değeri temsil eder.

Kisaltmalar	Açıklamalar
ESA	Evrişimli sinir ağları
2D	İki boyutlu
FDI	Dünya dış hekimliği federasyonu
C^{14}	Karbon-14
M	Tüm dişlerden elde edilen oranların ortalaması
W	Pulpa genişliği
L	Pulpa uzunluğu
KIBT	Bilgisayarlı tomografi
Mikro- BT	Mikro bilgisayarlı tomografi
3D	Üç boyutlu
BT	Bilgisayarlı tomografi
MRG	Manyetik rezonans görüntüleme
YSA	Yapay sinir ağları
ESA	Evrişimli sinir ağı
GPU	Grafik işlem birimi
CPU	Merkezi işlem biriminde
NAS	Neural architecture search (Ağ mimarisi arama)
MSE	Ortalama karesel hata
RMSE	Karekök ortalama karesel hata
R^2	Açıklayıcılık katsayısı
MAE	Ortalama mutlak hata
SSR	Artık kareler toplamı
SST	Toplam kareler toplamı

1. GİRİŞ

Bireylerin kronolojik yaşının tespiti; adli tıp, antropoloji, ortodonti ve genel diş hekimliği gibi birçok disiplinde kritik bir rol oynamaktadır. Adli bilimlerde kimliklendirme süreçlerinin temel bir bileşeni olan yaş tayini; özellikle kitlesel felaketler, göçmenlik prosedürleri veya cezai ehliyetin belirlenmesi gibi hukuki süreçlerde ve hatta spor müsabakalarında yaş kategorizasyonu gibi hukuki ve sosyal konularda büyük önem taşımaktadır [1, 2]. Adli diş hekimliği, bu süreçte dişlerin gelişimsel ve dejeneratif değişikliklerinden faydalanarak yaş tahmini yapma konusunda önemli bir disiplin olarak öne çıkmaktadır [3]. Dişler, insan vücudundaki en dayanıklı yapılar arasında yer alması ve yaşam boyunca belirli bir gelişim ve değişim sürecinden geçmesi nedeniyle yaş tayini için güvenilir biyolojik göstergeler sunmaktadır [4].

Geleneksel olarak dental yaş tahmini, dişlerin gelişimsel evreleri ve morfolojik değişimlerine dayalı olarak manuel yöntemlerle gerçekleştirilmektedir. Çocuk ve adolesanlarda diş sürme ve mineralizasyon süreçleri nispeten öngörülebilir sonuçlar verse de yetişkin bireylerde bu süreç daha karmaşık olmaktadır. Diş gelişiminin tamamlandığı yetişkinlerde, sekonder dentin birikimi, pulpa odasının daralması ve diş aşınması gibi daha özellikli ve bireyler arası değişkenliği yüksek morfolojik belirtiler ön plana çıkar [5]. Alan uzmanları tarafından yürütülen bu manuel değerlendirmeler, yoğun iş yükü gerektirmesi ve doğası gereği öznel yargılara açık olması gibi sınırlılıklara sahiptir. Bu durum, özellikle yetişkin popülasyonunda nesnel ve tekrarlanabilir sonuçlar elde etmeyi zorlaştırmaktadır. Ayrıca, çok sayıda radyografin manuel olarak incelenmesi, yüksek iş yüküne neden olmakta, bu da özellikle büyük veri setleriyle çalışırken pratik olmayan bir durum yaratmaktadır [6].

Son yıllarda, geleneksel yöntemlerin bu kısıtlılıklarını aşmak amacıyla yapay zeka, özellikle de derin öğrenme, güçlü bir alternatif olarak ortaya çıkmaktadır. Yapay zeka, insan zekasına özgü öğrenme, akıl yürütme ve karar verme süreçlerini taklit edebilen bilgisayar sistemleri olarak tanımlanmaktadır. Bu disiplin; makine öğrenmesi, derin öğrenme ve yapay sinir ağları gibi alt alanları kapsamakta ve verilerden anlamlı örüntüler çıkararak öngörülerde bulunmayı mümkün kılmaktadır [7].

Makine öğrenmesi, istatistiksel yöntemlerden yararlanarak modellerin veriler üzerinden öğrenmesini sağlarken; derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla karmaşık

ve soyut özelliklerin otomatik olarak öğrenilmesine olanak tanımaktadır [7]. Veri biliminin gelişimiyle birlikte derin öğrenme, özellikle klinik tıp ve görüntüleme alanlarında uzman doğruluğuna yakın ya da daha yüksek seviyede sonuçlar elde edilmesine imkan vermektedir [8-11]. Özellikle bilgisayarlı görme çalışmalarında kullanılan evrişimli sinir ağları (ESA), piksel tabanlı görüntü özelliklerini doğrudan işleyebilmekte ve nesne tespiti, görüntü sınıflandırması ile segmentasyon gibi görevlerde yüksek başarı göstermektedir [8]. Bu yöntemler diş hekimliği alanında da yaygın biçimde uygulanmış olup, dental görüntüler üzerinden kronolojik yaş tahminine yönelik araştırmalara olan ilgi giderek artmaktadır [12].

Panoramik diş radyografileri, diş hekimliğinde yaygın olarak kullanılan, tüm dişleri, çeneleri ve çevreleyen yapıları tek bir görüntüde gösteren iki boyutlu (2B) radyografik görüntülerdir. Bu radyografiler, düşük radyasyon dozu, geniş anatomik alan kapsamı ve kolay elde edilebilirliği nedeniyle yapay zeka tabanlı yaş tahmini modelleri için ideal bir veri kaynağı sunmaktadır [13]. Panoramik radyografi görüntüleri, dişlerin gelişim aşamaları, sürme durumları, kök morfolojileri ve pulpa boşluğundaki değişiklikler gibi yaş tayini için önemli olan birçok bilgiyi içermektedir. Yapay zeka modelleri, bu görüntülerdeki karmaşık örüntüleri analiz ederek, insan gözünün fark edemeyeceği veya yorumlamakta zorlanacağı detayları yakalayabilir ve yaş tahmini sürecini otomatik hale getirebilir [8, 9].

Literatürde, derin öğrenme kullanılarak yapılan yaş tahmini çalışmaları genellikle çocuk ve ergen popülasyonları ile belirli yaş eşiklerinin sınıflandırılmasına odaklanmıştır [14, 15]. Ancak yetişkin bireylerde, geniş bir yaş aralığında doğrudan kronolojik yaşın sayısal olarak tahmin edilmesine yönelik çalışmalar nispeten sınırlıdır [10]. Bu çalışma, literatürdeki bu boşluğu doldurmayı hedeflemektedir. Bu çalışmanın temel amacı; manuel ve kişi bazlı ölçümlerine ihtiyaç duymadan, panoramik radyografi görüntüleri üzerinden yetişkin bireylerin kronolojik yaşını tam otomatik olarak tahmin eden bir derin öğrenme sistemi geliştirmektir. Bu kapsamda, diş ve çene yapılarındaki karmaşık morfolojik desenlerin ESA modelleri aracılığıyla incelenerek yüksek doğrulukta tahminler elde edilmesi amaçlanmıştır. Ayrıca, biyolojik varyasyonun modelleme sürecine dahil edilmesinin performansa etkisini değerlendirmek amacıyla cinsiyet bilgisi de bir parametre olarak kullanılmıştır. Bu sayede geliştirilen modelin, yaş tayini süreçlerini hızlandıran, objektif ve manuel yöntemlerin sınırlılıklarını gideren otomatik bir karar destek sistemi olması amaçlanmaktadır.

2. GENEL BİLGİLER

2.1. Adli Bilimler ve Adli Diş Hekimliği

Adli bilimler, suçların aydınlatılması, kimlik tespiti ve hukuki süreçlere bilimsel destek sağlamak amacıyla gelişen multidisipliner bir bilim dalıdır. Adalet sisteminin bir parçası olan bu bilim dalı, suç soruşturmalarında delil toplama, analiz etme, rapor hazırlama ve mahkemeye sunma aşamaları ile adaletin sağlanmasında kritik bir öneme sahiptir [16]. Adli bilimler, suç ve adli soruşturmaların bilimsel yöntemlerle aydınlatılmasını amaçlayan disiplinler arası bir alan olup, adli tıp, adli toksikoloji, adli antropoloji, adli diş hekimliği, adli genetik ve adli balistik gibi çeşitli alt dallara sahiptir [17].

Adli bilimlerin alt disiplinlerinden biri olan adli diş hekimliği veya adli odontoloji, bu kapsamda diş kanıtlarını kullanarak bireylerin kimliklendirilmesi, ısırık izi analizi, yaş ve cinsiyet tahmini gibi adli süreçlere katkıda bulunan önemli bir bilim dalıdır [18]. Adli diş hekimliği, hukuki süreçlerde dental kanıtların toplanması, analizi ve yorumlanmasıyla ilgili uzmanlaşmış bir diş hekimliği alanıdır. Dünya Diş Hekimliği Federasyonu (FDI) adli diş hekimliğini, “Adaletin sağlanması amacıyla, diş kanıtlarının doğru şekilde toplanması, incelenmesi ve elde edilen bulguların uygun şekilde değerlendirilerek sunulması” olarak tanımlamaktadır [19].

2.2. Adli Kimliklendirme

Adli diş hekimliği uygulamalarında, ölüm öncesi (antemortem) ve ölüm sonrası (postmortem) dental kayıtlar kimliklendirme sürecinde kritik öneme sahiptir. Antemortem kayıtlar, bireyin hayattayken elde edilen dental verileri ifade ederken; postmortem kayıtlar, ölüm sonrası elde edilen dental bulguları kapsar; her iki kayıt türünün temel amacı, bireyin kimliğini belirlemek üzere karşılaştırmalı analiz yaparak kimliklendirme sürecine katkı sağlamaktır. Özellikle büyük çaplı afetlerde ve adli vakalarda, bu kayıtların standartlara uygun şekilde toplanıp karşılaştırılması, yüksek doğrulukla kimlik tespiti yapılmasına olanak tanır [20]. Afet mağdurlarının kimliğinin tespitinde dental materyallerin sistematik olarak ilk kez kullanıldığı olay, 1898 Bazar de la Charité yangınıdır. Bu trajik olayda, 126 kişinin hayatını kaybetmiş ve birçok kurbanın bedenleri tanınamayacak derecede hasar görmüştür. Felaketin kurbanlarının büyük kısmı, yalnızca diş kayıtları kullanılarak kimliklendirilebilmiştir [21]. Bu olay, Dr. Oscar Amoëdo’nun adli odontoloji alanındaki ilk

kapsamlı akademik çalışma olan L'Art Dentaire en Medicine Legale adlı çalışmasını yazmasına öncülük etmiştir [18]. Afet mağdurlarının kimlik tespiti, bu tarz doğa olaylarının öngörülemez yapısı nedeniyle adli bilimler çalışanları için büyük zorluklar içermektedir [22]. Yangın gibi yüksek sıcaklık içeren afetlerde, diş kanıtları kimliklendirme sürecinde en güvenilir verilerden biri olarak kabul edilmektedir [23]. Vücut yapılarının tamamen bozulduğu durumlarda, sahada çalışan adli diş hekimlerinin varlığı, diş kanıtlarının doğru şekilde toplanmasını ve korunmasını sağlayarak kimliklendirme başarısını artırmaktadır. Bu süreçlerin etkinliğini artırmak için standart prosedürler önerilmiştir [24]. Dental kayıtların düzenli tutulduğu ülkelerde, ileri derecede hasar görmüş cesetlerden kimlik tespitinde dental kayıtlar önemli bir belge olmaktadır. Günümüzde, kitlesel felaketlerde gerçekleştirilen kimlik tespit çalışmalarında dental bulguların kullanımıyla elde edilen başarılı sonuçlar önemli seviyededir [25]. Amerika'da gerçekleşen 11 Eylül saldırılarında kurbanların %60'ının kimliklendirilmesinde diş kayıtlarından faydalanılmıştır [26]. Kimliği belirsiz bir cesetle karşılaşıldığında, yaşı belirlenmesi kimlik tespit sürecine önemli ölçüde katkı sağlar [27].

2.3. Kronolojik Yaş ve Biyolojik Yaş

Kronolojik yaş, bir bireyin doğumundan itibaren geçen süreyi ifade eden takvim yaşıdır. Adli odontolojinin temel amaçlarından biri, kimlik tespiti sürecinin bir parçası olarak bireyin kronolojik yaşını tahmin etmektir. Biyolojik yaş ise bir bireyin büyüme, gelişme veya dejenerasyon düzeyini yansıtan ve bu düzey üzerinden tahmin edilen yaşı ifade etmek için kullanılır. Biyolojik yaş ile kronolojik yaş arasında pozitif bir korelasyon bulunmaktadır. Ancak, biyolojik yaş doğrudan kronolojik yaşı yansıtmaz; bu iki kavram arasında bireyler arası biyolojik varyasyonlardan kaynaklanan sapmalar görülebilir. Bireyin biyolojik yaşı belirlenirken, dişler ve iskeletteki morfolojik yapılarla birlikte boy, kilo ve cinsiyet özellikleri birlikte ele alınarak değerlendirilir [28, 29]. Adli diş hekimleri, esas olarak kronolojik yaşa yani doğumdan ölüme kadar geçen süreye odaklanır. Adli diş hekimliği, bireyin morfolojik gelişimine dayalı verileri analiz ederek ölüm anındaki takvim yaşını tahmin etmeye çalışır [30].

2.4. Dental Yaş Belirleme

Kronolojik yaş tahmini tarih boyunca, bireylerin doğum tarihlerinin doğum belgelerinin eksikliği veya doğum belgelerinin şüpheli olması nedeniyle doğrulanamadığı durumlarda hukuki prosedürlerde rutin olarak kullanılmaktadır. Dişler, insan vücudunun çıplak gözle görülebilen tek sert doku yapısı olması nedeniyle kronolojik yaşla ilişkilendirilmeleri oldukça eski zamanlara dayanmaktadır [31]. Antik Romalıların, askere alınacak kişilerin yaşının uygunluğunu belirlemek için ikinci molar dişlerin sürmesin değerlendirdikleri düşünülmektedir [18]. 19. yüzyılda İngiliz fabrika yasası, çocuk işçilerin çalışma şartlarını düzenlemek için dişlerin yaş göstergesi olarak kullanılmasıyla ilgili belgelenmiş ilk hukuki örneklerdendir [31].

Çocukluk, ergenlik ve genç yetişkinlik dönemlerindeki bireyler için yaş belirleme, özellikle doğum belgesinin bulunmadığı durumlarda, cezai sorumluluk, çocuk işçiliği düzenlemeleri, evlat edinme, yasadışı göçmenlik, reşit olma ve evliliğe uygunluk gibi hukuki süreçlerin yönetilmesinde kritik bir rol oynamaktadır [32]. Günümüz toplumunda adli diş hekimliğinde yaş tespiti önemi; kitlesel felaketlerde kurbanların kimliklerinin tespitinde yaş ayrımı, ölüm anındaki yaşın tespiti, göçmenlik gibi toplu nüfus hareketlerinde bireylerin cezai ehliyet durumlarının belirlenmesi gibi çeşitli adli ve hukuki süreçleri içermektedir [31]. Böyle durumlarda insan dişlerinin bireye özgü özellikleri, tarih boyunca kişilerin kimlik tespitini kolaylaştırmıştır.

Dişler, sert yapıları nedeniyle cesetlerin bozulma süreçleri, yüksek sıcaklık ve çeşitli mekanik ve fiziksel etkenlere karşı dirençlidir. Dişlerin bütünlüklerini uzun süre koruyabilmeleri nedeniyle diş yoluyla yaş tahmini bugüne kadar kabul gören ve güvenilir bir yöntem olmaya devam etmektedir [33, 34]. Bu özellikleri ile diş yapılarının yaş tahmininde yaygın olarak kullanılmasının nedeni, kemik dokulara göre mineralizasyon süreçlerinin çevresel, genetik ve beslenme gibi dış etkenlerden daha az etkilenmesidir [35, 36]. Radyolojik tekniklerin gelişmesiyle birlikte diş gelişimi ve mineralizasyonu invaziv olmayan yöntemlerle daha hızlı şekilde değerlendirilebilmekte ve kronolojik yaş tahmini yapılabilmektedir. Dişlere ait radyografilerden yararlanılarak yaş tahmini, diş tomurcuklarının görünümü, kronun mineralizasyon derecesi ve sürmesi, açık apekslerin ölçümü, diş/pulpa oranları ve üçüncü molarların gelişimi gibi farklı özellikleri içeren değerlendirilme metotlarına dayanır [20].

2.4.1. Çocuklarda yaş belirleme

Çocuklarda yaş belirlemeye yönelik çalışmalar, süt ve daimi dişlerin sürme evrelerini değerlendirerek kronolojik yaş tahmini etmeyi amaçlamaktadır [20]. Çocuklarda ve genç adolesanlarda diş gelişimi sürecine dayalı yapılan yaş tayini metotları daha başarılı sonuçlar vermektedir. Bu durum, bu yaş grubuna yönelik yapılan çalışmaların yetişkin bireylerden daha fazla olmasına neden olmaktadır [37]. Çocuklarda kullanılan yaş belirleme yöntemlerinden, Haavikko metodu, 2-13 yaş aralığındaki çocukların panoramik radyografileri üzerinden dört kalıcı dişin 12 gelişim aşamasına göre değerlendirilmesine dayanan bir yaş tahmin yöntemidir [38]. Daha uzun vadeli dönemler için Schour & Massler, Ubelaker, Blenkin & Taylor ve Londra Diş Gelişimi ve Erüpsiyon Atlası gibi farklı dental yaş atlasları geliştirilmiştir. Bu atlaslar dişlerin gelişim aşamalarını grafiksel olarak ifade etmekte ve karşılaştırma yoluyla yaş tespitini yapmayı sağlar [39-42]. Bu metotlar dışında bazı araştırmacılar diş gelişim evrelerinin skorlanmasına dayalı farklı dental skor sistemleri geliştirerek, kronolojik yaşın tahmininde kullanmışlardır. Nolla metodu, Gleiser ve Hunt metodu, Demirjian metodu gibi yöntemler bu alanda en çok bilinenleridir [43-45]. Nolla metodu, mandibula ve maksillada yer alan daimi dişlerin gelişim sürecini başlangıçtan tamamlanmaya kadar on evreye ayırmış ve her bir evreye 0 ile 10 arasında değişen skorlar atamıştır. Radyografik değerlendirme sırasında, dişlere ait skorların toplamı ile bireyin diş gelişim skoru elde edilmekte; bu skor, referans tablo ile karşılaştırılarak bireyin dental yaşı belirlenmektedir [43]. 1973 yılında Demirjian ve çalışma arkadaşları, sol mandibulada yer alan yedi daimi dişin panoramik radyograflar üzerindeki gelişim evrelerini A'dan H'ye kadar sekiz aşamada tanımlayarak dental maturasyonun tahminine yönelik sayısal bir sistem geliştirmiştir. Her bir dişin gelişim düzeyi ayrı ayrı puanlanmakta, elde edilen toplam skor ise cinsiyete özgü referans tablolar aracılığıyla bireyin dental yaşının tahmin edilmesinde kullanılmaktadır [44]. Yaş tahmini için farklı bir yaklaşım öneren Cameriere ve arkadaşları, yaş tahmini için alt çenenin sol tarafındaki yedi daimi dişin açık apekslerini ölçerek diş yüksekliğine göre normalize edilen ve kronolojik yaş ile güçlü negatif korelasyon gösteren bir model geliştirmiştir. Bu yöntemde, bireyin cinsiyeti, normalize edilmiş diş ölçümleri ve kök gelişimi tamamlanmış diş sayısını temel alan bir regresyon modeli kullanılmıştır [46].

2.4.2. Yetişkinlerde yaş belirleme yöntemleri

Çocuk ve adolesanlarda diş gelişim tabloları ile radyografik verilerden yararlanılarak yaş tahmini kolayca yapılabilse de diş gelişiminin tamamlandığı yetişkinlerde bu süreç daha karmaşık bir sorundur. Bu nedenle, yaşla birlikte dişlerde ve çevre dokularda meydana gelen morfolojik değişimlerin incelenmesine dayalı çeşitli yöntemler geliştirilmiştir. Bu yöntemler arasında dental atrizyon, kök transparanlığı, sement apozisyonu, periodontal çekilme, kök rezorpsiyonu, diş renginde koyulaşma, sekonder dentin apozisyonu, aspartik asit rasemizasyonu, telomer kısalması ve radyoaktif karbon-14 analizine dayalı teknikler yer almaktadır [47-58].

Gustafson, 1950 yılında yetişkin bireylerde dental yaş tahmini amacıyla yaşa bağlı morfolojik değişimlere dayanan ilk bilimsel yöntemi geliştirmiştir. Bu yöntemde atrizyon, sekonder dentin birikimi, periodontal çekilme, sement apozisyonu, kök rezorpsiyonu ve kök transparanlığı olmak üzere altı parametre, her biri 0 ile 3 arasında puanlanarak değerlendirilmiştir [47].

Dişlerde gözlenen atrizyon, yaşla birlikte en belirgin şekilde ortaya çıkan değişikliklerden biridir. Atrizyon ve oklüzal aşınmanın değerlendirilmesi amacıyla literatürde çeşitli skorlama sistemleri geliştirilmiştir [48]. 2002 yılında yapılan farklı bir araştırmada ise iskelet kalıntılarındaki molar dişlerin kuron yüksekliği ölçülerek aşınma düzeyi kaydedilmiş; kuron yüksekliği ile bireyin yaşı arasında istatistiksel olarak anlamlı ve doğrusal bir ilişki tespit edilmiştir [49]. Bazı çalışmalar, beslenme alışkanlıkları, diş eksiklikleri ve sosyal faktörler gibi etkenlerin diş aşınmalarında farklılıklara yol açabileceğini belirterek, yalnızca dental aşınmanın değerlendirmesine dayalı yaş tahmininin güvenilir olmadığını ortaya koymuştur. Ayrıca, tüm dişlerin karşıt dişlerle temas etmediği ve bu nedenle bazı dişlerin atrizyona uğramayabileceği belirtilmiş; bu nedenle, atrizyonun tek başına kullanılması durumunda yaş tahmininde hatalı sonuçlar elde edilebileceği ifade edilmiştir [50].

Sement apozisyonuna dayalı yöntemlerde, yaşla birlikte sement kalınlığındaki artış ölçülebilir bir değişken olarak değerlendirilmekte ve kökten alınan ince kesitler histolojik olarak incelenmektedir. Solheim'in 1990'daki çalışmasında, sement kalınlığının farklı skorlama sistemleriyle değerlendirildiği ve yaşla olan korelasyonun diş tiplerine göre değişiklik gösterdiği; özellikle üst premolarlar dışında, kökün apikal üçte birinden alınan

lingual ve vestibüler yüzeylerdeki sement kalınlığı toplamının yaşla en güçlü ilişkiyi verdiği, ayrıca yaş ilerledikçe sement birikiminin azaldığı belirtilmiştir [51].

Proteinlerin temel yapı taşları olan aminoasitler doğada yirmi farklı türde bulunur. Vücutta sentezlenen proteinler başlangıçta yalnızca L-enantiyomerlerini içerirken, yaşla birlikte yavaş ilerleyen rasemizasyon süreciyle D-enantiyomerlerine dönüşür; bu kimyasal dönüşüm ölüm sonrasında da devam eder. Aspartik asit ise rasemizasyona en yakın aminoasit olup, vücutta beyin, kemik, göz merceği ve diş dokularında bulunur [52]. Helfman ve Bada, 1975 yılında gerçekleştirdikleri çalışmalarda, amino asit rasemizasyonunu inceleyerek yaş ile mine ve koronal dentin içindeki aspartik asitteki D-/L- enantiyomer oranı arasında anlamlı bir korelasyon tespit etmişlerdir [52, 53]. Aspartik asit rasemizasyonu ile yaş arasında pozitif bir ilişki saptanmış olsa da uygulanan yöntemlerdeki farklılıklar nedeniyle rasemizasyon oranları ve yaş tahminlerinde tutarsızlıklar gözlemlenmiştir. Bu nedenle Waite ve arkadaşları, rasemizasyon araştırmalarında standart bir yöntemin benimsenmesi ve uluslararası düzeyde fikir birliğine varılması gerektiğini öneren bir çalışma yayımlamışlardır [54].

Telomerler, ökaryotik hücrelerin kromozom uçlarında bulunan özelleşmiş heterokromatik yapılardır. Hücre bölündükçe telomer boyları kısalmakta ve bu durum hücresel yaşlanma sürecini göstermektedir. Literatürde, yaş ile telomer uzunluğundaki azalma arasında güçlü bir korelasyon olduğunu bildiren çalışmalar mevcuttur [55, 56].

Atmosferdeki karbon-14 (C14) seviyesi yıllara göre değişiklik göstermekte olup, 1944 öncesinde sıfır düzeyindeyken, 1955'teki nükleer faaliyetler sonrası belirgin şekilde artmıştır. C14, insan vücuduna çeşitli yollarla geçer ve mine dokusu gelişimini tamamladıktan sonra yenilenmediği için içerdiği C14 miktarı, gelişim dönemindeki atmosferik seviyeyi yansıtır. Bu nedenle, gelişim zamanı bilinen dişlerin C14 düzeyine bakılarak yaş tahmini yapılabilir; ancak 1944'ten önce doğan bireyler için bu yöntem uygulanamaz [57].

Yaşa bağlı diş rengi değişimlerinin yaş tahmininde kullanımı üzerine çeşitli çalışmalar yapılmış olsa da yöntemin objektifliği bireysel renk farklılıkları, patolojik durumlar, travmalar ve postmortem değişiklikler nedeniyle sınırlıdır. Anterior dişlerin spektrofotometre ile analiz edildiği bir çalışmada, yaş ilerledikçe diş renginin koyulaştığı

gözlemlenmiş; ayrıca cinsiyetin ve diş tiplerinin bu değişim üzerinde anlamlı bir etkisinin bulunmadığı bildirilmiştir [58].

2.4.3. Yetişkinlerde radyografik yaş belirleme yöntemleri

Bireyin kronolojik yaşını tahmin etmek amacıyla, diş yapısının morfolojik ve radyolojik özelliklerine dayalı çeşitli yöntemler geliştirilmiştir. Bu doğrultuda, pulpa boyutu ile sekonder dentin birikimini esas alan nicel analiz teknikleri öne çıkmaktadır. Bu metotlardan en çok bilinenleri araştırmacıların kendi adları ile tanımlanan Drusini, Cameriere ve Kvaal metotlarıdır. Ayrıca son zamanlarda üç boyutlu görüntüleme yöntemlerinin gelişimi ile birlikte diş ve pulpa hacmini ölçen çalışmalarda yürütülmüştür [59-69].

Drusini Metodu

Drusini, diş pulpasının zamanla sekonder dentin birikimiyle daralması prensibine dayanarak koronal pulpa odasının uzunluğu ile kuron uzunluğunun arasındaki oranı, koronal indeks değerini hesaplamak için kullanmıştır. Koronal İndeks değerini regresyon analizi kullanarak değerlendirmiş ve yaş tahmini amacıyla uygulamıştır [59].

1997 yılında, panoramik radyografiler kullanılarak mandibular premolar ve molar dişlerin koronal indeks değerlerine dayalı bir regresyon modeli geliştirmiştir. Bu çalışmada, cinsiyetin yaş tahmini üzerinde anlamlı bir etkisi olmadığı ancak özellikle erkek molar dişlerin koronal indeks değerleriyle daha yüksek doğruluk oranları elde edildiği belirtilmiştir. En iyi tahmin, erkek molar dişleri ile yapılmış olup, vakaların %81,4'ünde ± 5 yıl hata payı ile elde edilmiştir [60].

Cameriere Metodu

Cameriere ve arkadaşları, yaş tahmini için ağızda en uzun süre kalan ve ölçüm açısından en uygun dişler olması nedeniyle maksiller kanin dişlerini kullanmıştır. Çalışmalarında pulpa/kök uzunluğu oranı, pulpa/diş uzunluğu oranı ve üç farklı seviyeden pulpa/kök genişliği oranı ve pulpa/diş alanının oranını incelemişlerdir. Çalışmada değerlendirilen parametrelerden en iyi korelasyonu pulpa/diş alan oranı değerlerinin gösterdiği bulunmuştur. Cinsiyetin yaş tahmininde fark göstermemesi gerekçesiyle cinsiyet bazlı regresyon modelleri kullanılmamıştır [61].

Cameriere ve arkadaşlarının çalışması sonucunda, aşağıda verilen regresyon modeli geliştirilmiş ve yaş hesaplanmıştır.

$$Yaş = 84,31 - 473,86 \times \left(\frac{\text{pulpa alanı}}{\text{diş alanı}} \right)$$

Kvaal Metodu

Kvaal ve arkadaşları, diş pulpasının boyutu ile yaş arasındaki ilişkiyi analiz ederek kronolojik yaş tahmini için bir yöntem geliştirmek amacıyla aynı bireye ait altı diş üzerinde ölçümler yapmıştır. Maksiller ve mandibular farklı dişler üzerinde ölçümler gerçekleştirilmiştir. Maksiller dişler, santral ve lateral keser dişler ikinci premolar dişler, mandibular dişler ise lateral kesici dişler, kanin ve birinci premolarlardan oluşmaktadır. Ölçümlerde diş uzunluğu, pulpa uzunluğu, kök uzunluğu ve üç farklı seviyeden ölçülen pulpa genişliğini yer almaktadır. Bu parametreler ile pulpa ve diş ölçümleri arasındaki oranlar hesaplandı ve regresyon analizi kullanılarak yaş tahmin modelleri oluşturuldu.

En iyi tahmin modeli, tüm dişlerden elde edilen oranların ortalaması ile oluşturulmuştur.

Yaş tahmini için en güçlü regresyon modeli şu şekilde ifade edilmiştir:

$$Yaş = 129,8 - 3164(M) - 66,8(W - L)$$

Burada; M, tüm dişlerden elde edilen oranların ortalamasını, W- L, pulpa genişliği ile pulpa uzunluğu arasındaki farkı temsil etmektedir [62].

Diş-Pulpa Hacmine Göre Yöntemler

Sekonder dentin birikimi, dişlerin olgunlaşma sürecinden sonra da hayat boyu devam eder. Bu birikim ile pulpa hacmi sürekli azalır [63]. Buna dayanarak, pulpa boşluğu boyutundaki azalma miktarı, yetişkinlerde yaş tahmini için etkili bir morfolojik kriter olarak düşünülebilir [64]. Bu yaklaşımla yapılan erken dönem araştırmalarında diş yapısını görüntülemek için periapikal, panoramik radyografiler gibi 2B görüntüleme teknikleri kullanılmıştır. Ancak, bu görüntüleme teknikleri distorsiyon ve magnifikasyon gibi sorunlar nedeniyle bazı kısıtlamalara sahiptir [65]. 2B görüntüleme yöntemlerindeki bu kısıtlamalar nedeniyle, özellikle yetişkinlerde sekonder dentin birikiminin daha detaylı incelenmesi için Konik Işınlı

Bilgisayarlı Tomografi (KIBT) ve Mikro Bilgisayarlı Tomografi (Mikro- BT) gibi farklı üç boyutlu (3B) görüntüleme teknikleri kullanılarak çalışmalar gerçekleştirilmiştir [66-69].

2.5. Yaş Tayininde Kullanılan Radyolojik Yöntemler

2.5.1. Periapikal radyografi

Periapikal radyografiler, dişin tamamını ve dişleri çevreleyen kemiği değerlendirme imkanı sağlayan intraoral radyografik tekniktir. Bu radyografiler uygun koşulda uygulandığında diş hekimliği pratiğinde, klinik muayeneyi tamamlayacak en önemli tanısal bilgileri sağlamaktadır. Periapikal radyografide, paralel teknik ve açıortay tekniği olmak üzere sıklıkla kullanılan iki adet intraoral projeksiyon bulunmaktadır. Paralel teknik, görüntüde distorsiyonu azaltarak görüntü kalitesi için en faydalı teknik olmasına rağmen klinik pratikte ağız anatomisinin kısıtlaması dolayısıyla uygulanması zordur. Paralel tekniği uygulamanın mümkün olmadığı durumlarda belirli açı değerlerine göre belirlenen açıortay tekniği kullanılmaktadır [70].

2.5.2. Panoramik radyografi

Panoramik görüntüleme hem maksiller hem de mandibular dental arklar ile çevresindeki yapılarını tek bir görüntüde birleştiren bir tekniktir. Bu yöntem, belirli bir vücut katmanını seçici olarak görüntüleyen tomografik bir görüntü oluşturur. Panoramik radyografide, bir X-ışını kaynağı ve görüntü reseptörü hastanın başı etrafında döner ve içindeki nesnelerin net bir şekilde görüntülediği kavisli bir odak ark alanı (focal trough) oluşturur. Bu odak alanının önünde veya arkasında bulunan nesneler bulanıklaşır ve büyük ölçüde görünmez hale gelir. Panoramik görüntüleme, çene kırıkları gibi travma değerlendirmeleri, üçüncü molarların konumlandırılması, büyük lezyonların saptanması, diş gelişimi ve sürme değerlendirmesi, gömülü diş veya kök ucu varlığı, temporomandibular eklem (TME) ağrısı ve gelişimsel anomalilerin incelenmesi gibi geniş çene taraması gerektiren klinik durumlar için en sık kullanılan yöntemlerden biridir [71].

2.5.3. Konik ışınlı bilgisayarlı tomografi

Bilgisayarlı Tomografi (BT) tıp pratiğinde rutin kullanılmaya başladıktan sonra 3D maksillofasiyal görüntüleme sıklıkla yer bulmuştur. Rutin kullanılan BT sistemlerinin en

önemli dezavantajı yüksek maliyetidir ve bu durumda diş hekimliği pratiğinde kullanımının sınırlı olmasına neden olmuştur. Bu dezavantajları aşmak için 2D sensör ile birlikte konik şekilli X ışını kullanılarak maksillofasiyal bölgenin görüntüsü elde edilmesi mümkün olmuştur [72]. Geliştirilen ilk nesil KIBT cihazları 1982 yılında tanıtılmış ve anjiyografi uygulamalarında kullanılmıştır [73].

Takip eden yıllarda diş hekimliğine özel KIBT cihazları geliştirilmiş ve klinik pratikte sıklıkla kullanılmaya başlanmıştır. Bu yeni sistemin en önemli avantajı BT'ye kıyasla düşük radyasyon dozu, yüksek rezolüsyonu ve düşük maliyetidir. Çok hızlı bir şekilde 3D dental görüntüleme standart haline gelen KIBT, BT'nin daha hızlı, kompakt ve güvenli bir versiyonudur. BT'ye göre en önemli dezavantajı düşük kontrast nedeniyle kemik ve yumuşak doku arasındaki ayırımının daha az olmasıdır [72].

2.5.4. Mikro- bilgisayarlı tomografi (Mikro- BT)

Mikro-BT, 5–10 μm^3 voksel boyutundaki taramalar yapabilen yüksek uzaysal çözünürlüğe sahip radyografik görüntüleme yöntemidir. Mikro-BT bu özelliği sayesinde BT ile kıyaslandığında aynı bölgede 1 000 000 kat daha küçük detayların görüntülenmesini mümkün kılar. Mikro-BT, özellikle hassas 3D analizler sağlayarak diş hekimliğinde birçok avantaj sunmaktadır. Bu yöntem, geleneksel 2D analizlere kıyasla istatistiksel olarak daha hassas veriler elde edilmesini sağlar ve ayrıca incelenen görüntünün dijital olarak yeniden yönlendirilmesine olanak tanır. Mikro-BT, bu özellikleri nedeniyle biyomedikal araştırmalarda, malzeme biliminde ve antropoloji gibi alanlarda yaygın olarak kullanılmaktadır [74, 75].

Vandevoort ve arkadaşlarının, farklı insan dişlerinde pulpa ve diş hacmi oranındaki yaşa bağlı değişiklikleri incelediği çalışma, Mikro-BT teknolojisi kullanılarak yapılan ilk yayınlanmış yaş tayini çalışmasıdır [66]. Sonraki yıllarda Mikro-BT kullanılarak yapılan farklı dental yaş tayini çalışmaları da yayınlanmıştır [76-78].

2.5.5. Manyetik rezonans görüntüleme

Manyetik rezonans görüntüleme (MRG), vücut dokularını detaylı bir şekilde görüntülemek için manyetik alan kullanan gelişmiş bir tıbbi görüntüleme tekniğidir. MRG için hasta büyük bir mıknatıs içine yerleştirilir ve vücuttaki hidrojen atomlarının manyetik alanda

diziliminden faydalanılarak bir görüntü oluşturulur. MRG tekniği temel olarak, vücuttaki hidrojen atomlarının bir dağılım haritasıdır. İnvaziv olmaması, iyonize radyasyon kullanmaması, yüksek yumuşak doku rezolüsyonu gibi çeşitli avantajlara sahiptir [79].

MRG'nin bu avantajlarından ötürü yaş tahmini çalışmalarında da kullanılmasının uygunluğu araştırılmıştır. Baumann ve arkadaşları, dişlerin sürme ve mineralizasyon aşamalarının tespitinde panoramik radyografiler ile MRG'yi karşılaştırmıştır. Çalışmada, iki teknik arasında yüksek düzeyde bir korelasyon bulunmuştur. Ayrıca MRG'nin mineralizasyonun değerlendirmesinde ve üst üçüncü molar dişin incelenmesinde daha başarılı olduğu belirtilmiştir [80].

Literatürde, üçüncü molar dişlerinin gelişim aşamaları MRG ile değerlendirilmiş ve elde edilen bulguların yaş tespiti için kullanılmasının güvenli sonuçlar verdiği bildirilmiştir [81-83].

2.6. Yapay Zeka

2.6.1. Yapay zeka nedir?

1955 yılında matematikçi John McCarthy “Yapay Zeka” terimini ortaya atmış ve bu kavramı, makinelerin zeka gerektiren görevleri yerine getirme potansiyelini açıklamak için kullanmıştır. Yapay zeka üzerine yapılan ilk araştırma projesi 1956 yılında John McCarthy'nin düzenlediği Dartmouth Konferansı olarak kabul edilir. Bu toplantı, 1970'lere kadar uzanan ve yapay zeka üzerine yoğun araştırmaların yapıldığı önemli bir dönemi başlatmıştır [84]. Yapay zeka'nın teorik temellerinin atıldığı bu dönemde, ülkemizde Prof. Dr. Cahit Arf, 1958 yılında “Makineler Düşünebilir mi?” başlıklı bir konferans vererek makinelerin düşünme yetisini ve insan zihniyle olan farklılığını ele almıştır. Arf'a göre makineler, önceden programlanmış görevleri yerine getirebilir ancak insan beyninin öngörülemeyen durumlara uyum sağlama yeteneğinden yoksundur [85]. Bu görüş, günümüzde makine öğrenimi ve derin öğrenme modellerinin geliştirilmesindeki temel amacı yansıtarak, kendi kendine öğrenme yoluyla makinelerin bilinmeyen durumlara uyum sağlamasını hedefleyen çalışmaların temelini oluşturur [86].

Günümüzde yapay zeka çalışmaları, insan zekasını taklit edebilen, rasyonel kararlar verebilecek ve belirli görevleri yerine getirebilen sistemler oluşturmayı amaçlar. Bu alan,

insan zihninin bilişsel süreçlerini modellemeye çalışan sistemlerden, mantık kurallarına dayalı akıl yürütme mekanizmalarına ve rasyonel karar verme prensiplerine dayanan otonom sistemlere kadar çeşitli yöntemleri içerir. Çağdaş yapay zeka araştırmaları, insan davranışını taklit etmekten ziyade, karar verme ve problem çözme süreçlerinde rasyonellik ilkesine dayalı etkili çözümler geliştirmeye odaklanıyor. Yapay zeka, doğal dil işleme, makine öğrenmesi, bilgisayarla görme ve robotik gibi disiplinleri kapsar ve günümüzde sağlık, mühendislik, eğitim ve çok çeşitli sektörlerde kullanılmaktadır [87].

1950'lerde yapay zeka kavramının ortaya çıkmasının ardından, 1980'lerde "makine öğrenimi" terimi kullanılmaya başlanmış, bunu takiben yapay sinir ağları ve derin öğrenme yaklaşımları geliştirilerek makinelerin verilerden öğrenme ve karmaşık desenleri tanıma yetenekleri ilerletilmiştir [84].

2.6.2. Makine öğrenmesi


Makine öğrenmesi, yapay zekanın bir alt dalı olup, makinelerin verilerden öğrenmesi ve tahminlerde bulunmasını sağlayan algoritmaları kapsar. Bu alan özellikle istatistiksel öğrenme ve desen tanıma tekniklerine dayanarak, çeşitli veri analiz yöntemleri geliştirir. Makine öğrenmesi; Denetimli Öğrenme, Denetimsiz Öğrenme ve Pekiştirmeli Öğrenme olmak üzere üç temel yaklaşım ile gerçekleştirilebilir [88].

Denetimli öğrenme, modelin etiketli veri kümesi üzerinden eğitildiği bir yöntemdir. Bu yöntemde her giriş verisi için önceden belirlenmiş bir çıkış değeri bulunur. Model, bu giriş-çıkış çiftleri arasındaki fonksiyonel ilişkiyi öğrenerek daha önce görmediği yeni veriler için doğru tahminler üretme yeteneği kazanır. Bu yaklaşım, sınıflandırma ve regresyon gibi temel problemleri çözmek için kullanılır [89].

Denetimsiz öğrenme yaklaşımında ise model etiketsiz veri üzerinden çalışır ve modelin verinin içsel yapısını veya gizli örüntülerini otomatik olarak keşfetmesini amaçlar. Bu süreçte model, veri noktaları arasındaki benzerliklere dayanarak kümeleme algoritmalarıyla gruplar oluşturur veya birliktelik kuralları gibi ilişkileri ortaya çıkarır [88].

Pekiştirmeli öğrenme, bir ajanın dinamik bir ortamla etkileşimi üzerinden öğrenmesini esas alır. Ajan, belirli bir hedefi maksimize etmek amacıyla deneme-yanılma yoluyla stratejiler geliştirir. Doğru eylemler için ödülleri alırken, yanlış eylemler için cezalar alır. Bu ödül-ceza

mekanizması, ajanın en yüksek kümülatif ödülü getiren optimal davranış politikasını öğrenmesini sağlar ve bu da genellikle ardışık karar verme süreçlerinde kullanılır. Bu üç ana öğrenme paradigması, makine öğrenmesi alanının temelini oluşturur [89]. Makine öğrenmesinin bu temel türleri ve görevleri, Şekil 2.1'de gösterilmiştir.



Şekil 2.1. Makine öğrenmesinin temel türleri ve görevleri. Kaynak: Singh ve arkadaşları [88]'dan uyarlanmıştır. (CC BY 4.0)

Makine öğreniminin amacı, makinelerin verilerden öğrenmesini kolaylaştırmak ve böylece sorunların insan müdahalesi olmadan çözülmesini sağlamaktır [84]. Günümüzde makine öğrenmesi, büyük veri analizi, tıbbi teşhis, finansal modelleme, otonom sistemler ve doğal dil işleme gibi birçok alanda kullanılarak yapay zeka çalışmalarının temelini oluşturmaktadır [89].


2.6.3. Yapay sinir ağları

İnsan beyni, nöronlardan oluşan bir sistemdir ve bu nöronlar sinyalleri iletip alarak haberci gibi işlev görür. Nöronlar, hücre aktivitesini kontrol eden bir çekirdekten, bilgiyi taşıyan dendritlerden ve sinyali dışarı taşıyan aksonlardan oluşur. Uyaranlar, akson boyunca ilerleyerek bir nöron ile diğeri arasındaki sinapsa ulaşır ve bir sonraki nörona iletilir. Birbirleriyle bağlantılı olan bu yapı sayesinde, öğrenme, öngörude bulunma ve örüntüleri tanıma gibi bilişsel yetenekler ortaya çıkar [90].

Biyolojik sinir hücrelerinin işlevlerini taklit eden ve Yapay Sinir Ağlarının (YSA) temelini oluşturan bileşenlere Yapay Sinir Hücreleri adı verilir. YSA, insan beyninin dijital bir versiyonu olarak tasarlanmış ve beynin bilgi işleme sürecini taklit eden bilgisayar programlarıdır. İnsanlar gibi, belirli örneklerden öğrenerek deneyim kazanır ve bilgiyi, verilerdeki örüntüleri ve ilişkileri tespit ederek toplar. Sinir ağları, yapay nöronlar aracılığıyla sinyalleri hesaplayan matematiksel modeller ve algoritmalara dayanır ve temel amacı, insan beynine benzer şekilde çalışan yapılar oluşturarak öğrenme, örüntü tanıma ve veri analizini gerçekleştirmektir [91].

Yapay sinir hücreleri, üç katman halinde ve her katman içerisinde paralel olarak bir araya gelerek YSA'nı oluştururlar. Bu katmanlar; girdi katmanı, ara katmanlar (gizli katmanlar) ve çıktı katmanıdır. Girdi katmanı, dış dünyadan gelen verileri alarak ağın diğer katmanlarına ileten bölümdür. Yapay nöronlar, bu verileri doğrudan işleyebileceği gibi, sadece ara katmanlara aktarma görevi de görebilir. Ara katmanlar (gizli katmanlar), ağın öğrenme sürecinin gerçekleştiği katmanlardır. Girdi katmanından gelen veriler, bu katmanlarda çeşitli dönüşümlerden geçirilerek işlenir. Ara katmanlar, ağırlıklı toplamalar ve aktivasyon fonksiyonları aracılığıyla veriyi anlamlandırır ve modelin öğrenmesini sağlar. Bir sinir ağı, probleminin karmaşıklığına bağlı olarak birden fazla ara katmana sahip olabilir ve her katmanda farklı özellikler öğrenilebilir. Çıktı katmanı, ara katmandan gelen işlenmiş verileri kullanarak ağın nihai çıktısını üretir [92].

Bir yapay sinir hücresi, dış ortamdan gelen $x_1, x_2, \dots, x_n$ şeklinde çok sayıda giriş sinyallerini alır. Her bir giriş sinyali, ilgili ağırlık katsayıları ($w_1, w_2, \dots, w_n$) ile çarpılır. Girişlerin ağırlıklarla çarpılmasıyla elde edilen değerler, toplama fonksiyonunda bir araya getirilir. Elde edilen bu toplam, hücrenin karar mekanizmasını belirleyen aktivasyon fonksiyonuna iletilir [92]. Aktivasyon fonksiyonu, gelen sinyali işleyerek yalnızca bir çıktı üretir; bu çıktı, yapay sinir hücresinin dışa verdiği yanıtı temsil eder. Böylece, çok sayıda girdiye rağmen yalnızca tek bir çıktı oluşturan yapay sinir hücresi, modelin öğrenme süreci ile hedef çıktılar arasında bir köprü işlevi görür [93]. Şekil 2.2 YSA hücresi modelini göstermektedir.



Şekil 2.2. Yapay sinir ağı şeması. Kaynak: Geetika Saini, Wikimedia Commons (CC BY-SA 4.0), https://commons.wikimedia.org/wiki/File:Artificial_neural_network.png

2.7. Derin Öğrenme

Derin öğrenme, çok katmanlı YSA'yı kullanarak, ham veriden anlamlı özellikleri ve desenleri otomatik olarak öğrenen bir makine öğrenmesi yöntemidir [94]. Geleneksel makine öğrenmesi modellerinde, anlamlı özellikler çıkarmak için insan müdahalesine dayalı mühendislik gerekirken, derin öğrenme bu süreci otomatik hale getirerek ham verilerden doğrudan gizli örüntüleri öğrenebilir. Bir derin öğrenme modeli, girdi verisini alarak her katmanda giderek daha soyut temsiller oluşturur ve geri yayılım (backpropagation) algoritması ile kendini optimize eder. Büyük veri setlerinden anlamlı temsiller çıkarabilme yeteneği sayesinde, derin öğrenme görüntü işleme ve tıbbi analizler başta olmak üzere birçok alanda önemli avantajlar sunmaktadır [95]. Yapay zekanın temel bileşenleri arasındaki ilişkiler Şekil 2.3'te gösterilmiştir.



Şekil 2.3: Yapay zekanın temel bileşenleri. Kaynak: Krichen [96]'den uyarlanmıştır (CC BY 4.0)

2.7.1. Evrişimli sinir ağları (Convolutional neural network)

İlk olarak LeCun ve arkadaşları tarafından gradyan temelli bir yaklaşımla geliştirilen bu sinir ağı yapısına evrişimli sinir ağı (ESA) adı verilmiştir [97]. Çok katmanlı ileri beslemeli bir yapay sinir ağı olan ESA başta görüntü analizleri olmak üzere çeşitli uygulamalarda kullanılır. Filtrelemeye dayalı bir yapıya sahip olan ESA, kullanılacak olan filtre ile görüntüdeki öznitelikleri belirginleştirir. Sinir ağı içerisindeki katmanlarla sınıflandırılacak öğelerin öznitelikleri belirlenerek sınıflandırıcı katmanı ile sınıflandırılır. Bu yapısı ile özellikle sınıflandırma ve tespit işlemlerinde başarıyla kullanılmaktadır. Görüntü verilerindeki başarısı nedeniyle derin öğrenme yapıları içerisinde en sık kullanılan sinir ağları evrişimli sinir ağları olmuştur [98]. Bu başarısı nedeniyle tıbbi görüntülerden yapılan tespit çalışmalarında yaygın olarak kullanılmaktadır [99].

ESA mimarisi; giriş katmanı, evrişim katmanı, aktivasyon katmanı, havuzlama katmanı, tam bağlı katman, drop out katmanı, sınıflandırma katmanı, yumuşatma katmanı ve normalizasyon katmanından oluşmaktadır.

2.7.2. Evrişimli sinir ağının katmanları

Giriş katmanı (Input layer)

Verinin ham olarak sinir ağlarına verildiği katmandır. Bu katmanda verilecek verinin boyutu donanımsal maliyet hesabı ve ağ başarısı değerlendirilerek uygun olarak seçilmelidir. Yüksek boyutlarda giriş verisi ağ başarısını artırmakla birlikte ihtiyaç duyulan bellek miktarını, eğitim ve test süresini de artırmaktadır.[100]

Evrişim katmanı

ESA'larının temelini oluşturan bu katmanda girdi verisi üzerinde daha önceden belirlenmiş bir filtrenin girdi verisi geçirilerek girdinin belirgin özelliklerinin ortaya çıkartılması amaçlanır. Bu katmanda yapılan filtreleme işlemi ile öğeye ait özellikler ağa daha iyi şekilde yansımış olacaktır. Yapılan bu işlemler sonucunda aktivasyon haritası oluşur [98].

Aktivasyon katmanı

Aktivasyon katmanı, genellikle evrişim katmanından sonra gelen doğrusal olmayan dönüşümlerin uygulandığı katmandır. Aktivasyon katmanının uygulanması, özellik haritalarına doğrusal olmayan yapılar kazandırarak, sınıflandırma algoritmalarının daha etkili şekilde öğrenmesini sağlar. Doğrusal olmayan fonksiyonlar, modelin doğruluk oranını artırırken öğrenme sürecini de hızlandırmaktadır [101].


Havuzlama katmanı

Boyut küçültme işlemi yapılarak hesaplama maliyetinin azaltıldığı ve aşırı öğrenmenin engellendiği katmandır. Farklı teknikler kullanılarak öznitelik haritalarındaki en belirgin bilgiler korunarak boyutu küçültür [102].

Tam bağlı katman

Bu katmandaki tüm nöronlar, önceki katmandaki aktivasyonların tamamına doğrudan bağlıdır. Evrişim katmanlarından elde edilen özellikleri düzleştirerek sınıflandırmaya hazır hale getirir. Nesneyi tanımlayan özelliklerin hangi sınıfa ait olduğu belirlenir. Son kararın

verildiği katmandır [102]. Şekil 2.4'te tipik bir evrişimli sinir ağı modelinin katmanları ve çalışma prensibi görülmektedir.



Şekil 2.4. Evrişimli sinir ağı diyagramı. Kaynak: Irisbox, Wikimedia Commons, (CC BY 4.0), https://commons.wikimedia.org/wiki/File:Convolutional_Neural_Network.png

Drop out katmanı

ESA eğitilirken ağın ezberlenmesi sonucu aşırı öğrenme adı verilen istenmeyen bir olay gerçekleşir. Drop out katmanı, derin öğrenme modellerinde aşırı öğrenmeyi önlemek için kullanılan düzenleme (regularization) yöntemlerinden biridir. Bu katman, her eğitim iterasyonunda rastgele seçilen nöronları devre dışı bırakarak modelin daha genelleştirilebilir bir yapıya sahip olmasını sağlar. Böylece model, belirli nöronlara aşırı bağımlılık geliştirmeden daha sağlam ve dengeli bir öğrenme süreci gerçekleştirir [103].

Sınıflandırma katmanı

Sınıflandırma katmanı, modelin giriş verisini belirli sınıflara ayırmasını sağlayan katmandır. ESA modellerinde tam bağlantılı katmandan sonra gelir ve modelin öğrendiği özellikleri kullanarak son karar mekanizmasını oluşturur [104].

Yumuşatma katmanı

Yumuşatma (softmax) katmanı, sınıflandırma katmanı olarak görev yapar ve kendisinden önceki tam bağlantılı katmandan gelen girdileri kullanarak sınıflandırma işlemini gerçekleştirir. Bu katman, verilen bir girdinin belirli bir sınıfa ait olma olasılığını hesaplayarak, hangi sınıfa

yakın olduğunu belirler. Derin öğrenme ağı içerisinde, her bir sınıf için olasılıksal hesaplaması yaparak sonuçları olasılıksal değerlere dönüştürür [98].

Normalizasyon katmanı

Normalizasyon katmanı, derin öğrenme modellerinde ağı daha stabil öğrenmesini sağlamak, eğitim sürecini hızlandırmak ve aşırı öğrenmeyi azaltmak için kullanılan bir bileşendir. ESA gibi derin öğrenme modellerinde, girdi verisinin dağılımını düzenleyerek ağı genelleme yeteneğini artırmada etkilidir [103].

2.7.3. Evrişimli sinir ağlarının eğitimi

Sinir ağlarının eğitimi için kullanılan veri kümesine eğitim seti adı verilir. Eğitim seti, modelin öğrenme sürecinde kullanılan verileri içerir ve modelin bu verileri bir kez işlemesine epoch adı verilir. Epoch sayısının düşük olması eksik öğrenmeye, çok yüksek olması ise aşırı öğrenmeye ve gereksiz uzun eğitim sürelerine yol açabilir [94].

ESA eğitimi, modelin belirli bir görevi öğrenebilmesi için ileri besleme ve geri yayılım süreçlerini içeren bir optimizasyon sürecidir. ESA eğitim süreci, modelin mimarisinin belirlenmesiyle başlar. Bu süreçte katmanlar tanımlanır ve sıralamaları belirlenir ve filtre boyutları ile sayıları gibi parametreler rastgele atanır. Oluşturulan modele eğitim setinden bir veri verilerek bir çıktı üretilir. Bu aşamaya ileri besleme denir. Çıktı ile hedef sonuçlar karşılaştırılarak hata değeri hesaplanır. Elde edilen hata değeri ağıdaki bütün ağırlıklara dağıtılması gerekmektedir. Bu aşamada, modelin hatalarını azaltmak için her bağlantının sonucu nasıl etkilediği hesaplanır ve ağırlıklar buna göre güncellenerek daha doğru tahminler yapması sağlanır. Eğitim süreci boyunca modelin başarımı, hata oranı ve doğruluk değerleri takip edilerek izlenir. Eğer modelin doğrulama aşamasındaki başarısı belirli bir süre boyunca artmazsa, eğitim süreci sonlandırılır. Eğitim tamamlandığında, en iyi performansı gösteren model kaydedilir ve test veri kümesi üzerinde değerlendirilerek modelin genelleme yeteneği ölçülür [100].

2.8. Derin Öğrenme Kütüphaneleri

Derin öğrenme kütüphaneleri, yapay sinir ağlarının tasarımı, eğitimi ve doğrulanması için geliştirilen güçlü araçlardır. Bu kütüphaneler, geliştiricilerin düşük seviyeli kodlarla

uğraşmadan model geliştirmelerine olanak tanır ve süreçleri daha verimli hale getirir. Her biri farklı ihtiyaçlara göre optimize edilen bu kütüphaneler, gerçek zamanlı uygulamalardan araştırma projelerine kadar geniş bir yelpazede kullanılmaktadır [105].

2.8.1. PyTorch

PyTorch, dinamik yapısı sayesinde derin öğrenme projelerinde yaygın olarak tercih edilen Python tabanlı güçlü ve popüler bir kütüphanedir. Matematiksel işlemleri gerçekleştirebilen ve tensör hesaplamalarını destekleyen PyTorch, grafik işlem birimi (GPU) üzerinden yüksek hızda çalışma olanağı sunan, güçlü bir derin öğrenme kütüphanesidir. Esnek ve kullanıcı dostu programlama arayüzü, araştırma süreçlerinin daha verimli yürütülmesine olanak tanımaktadır [106].

2.8.2. OpenCV

OpenCV, bilgisayarla görme temelli uygulamaların geliştirilmesinde yaygın olarak kullanılan, çok yönlü ve standart bir yazılım kütüphanesidir. Görüntü işleme, özellik çıkarımı, nesne ve desen tanıma, renk algılama gibi görevlerin yanı sıra; yüz ve jest tanıma, robotik sistemler, görüntü segmentasyonu ve artırılmış gerçeklik uygulamaları için de çeşitli modüller sunmaktadır. Çoklu sistem ve programlama dili desteğine sahip olması, farklı platformlarda etkin bir biçimde kullanılmasına olanak tanımaktadır [107].

2.8.3. TensorFlow

TensorFlow, makine öğrenmesi ve derin öğrenme modellerinin geliştirilmesine olanak sağlayan, açık kaynaklı olarak oluşturulmuş güçlü bir yazılım kütüphanesidir. Farklı programlama dillerini ve donanım ortamlarını desteklemesinin yanı sıra, veri akışı temelli hesaplama yapısı sayesinde paralel işlemeyi mümkün kılar [106].

2.8.4. Keras

Keras, Python tabanlı ve kullanıcı dostu bir derin öğrenme kütüphanesidir; model geliştirme, eğitim ve test süreçlerini kolaylaştırmak amacıyla tasarlanmıştır. Keras, aynı kodun değişmeden hem merkezi işlem biriminde (CPU), hem de GPU'da çalışmasını sağlar [106].

2.8.5. Caffe

Caffe, hızlı ve modüler bir yapıya sahip olacak şekilde tasarlanmış bir derin öğrenme kütüphanesidir. Model mimarileri ve optimizasyon işlemleri, doğrudan kod yazımı gerektirmeden yapılandırma dosyaları aracılığıyla tanımlanabilmektedir [105].

2.9. Medikal Alanda Yapay Zeka Uygulamaları

Sağlık hizmetlerinde yapay zeka uygulamalarının temel amacı sağlık sonuçlarını ve hasta deneyimlerini iyileştirmektir. Teknoloji ve bilişimdeki ilerlemeyle birlikte, yapay zeka artık modern sağlık hizmetlerinin önemli bir parçası haline gelmiş olup tıp uzmanları, hastalıkların teşhisi ve tedavi süreçlerini yürütmede yapay zeka algoritmalarını ve diğer uygulamalarını yaygın olarak kullanmaktadır [108].

Yapay zeka, tıp alanında teşhis, görüntü analizi, yoğun bakım verilerinin yorumlanması ve dalga formu analizi gibi birçok uygulamada kullanılmaktadır. Prostat kanseri, apandisit, safra taşı ve glokom gibi hastalıkların teşhisinde başarılı sonuçlar elde edilmiştir. Ayrıca, rahim ağzı, meme, mide, tiroit ve ürolojik kanserlerin sitolojik ve histolojik analizlerinde yapay zeka destekli sistemler kullanılmaktadır. Radyolojide; röntgen, ultrason, BT ve MRG görüntülerinin yorumlanmasıyla hastalıkların tespitine yardımcı olurken; elektrokardiyografi ve doppler ultrason analizleri sayesinde kalp hastalıkları, epilepsi ve kas-iskelet sistemi bozuklukları tanımlanabilmektedir. Yapay zeka, yoğun bakım hastalarında hemodinamik patenlerin incelenmesi gibi alanlarda da giderek daha fazla kullanılmaktadır [109]. Sağlık alandaki diğer çalışmalarda ise diz kireçlenmesinin otomatik tespiti, MRG ile şizofreni, Huntington ve Alzheimer hastalıklarının teşhisi, retina görüntülerinden diyabetik retinopati tespiti gibi farklı alanlarda yapay zeka uygulamaları kullanılmıştır [98].

Prognoz belirleme, uygun tedavi stratejilerinin planlanması ve hastaların takibi açısından son derece önemlidir. Yapay zeka algoritmaları kullanılarak kanser verilerinin değerlendirilmesi ile ilgili çalışmalar yapılmıştır. Meme ve kolorektal kanserli hastalarda hayatta kalma süresini tahmin edebilen, ayrıca akciğer ve prostat kanserlerinde tedavi sonuçlarını başarıyla öngörebilen yapay zeka modelleri bildirilmiştir [109].

2.9.1. Diş hekimliğinde yapay zeka uygulamaları

Diş hekimleri, teşhis koymak ve hastaları için en uygun tedavi seçeneğini belirlemek için edindikleri klinik deneyimi ve bilgileri kullanmak zorundadır. Bazı durumlarda, diş hekimleri klinik tanı koymak ve uygulanacak tedavinin prognozunu değerlendirmek için yeterli zamana ve deneyime sahip olmayabilir. Diş hekimlerinin karar verme süreçlerini iyileştirmek ve verimli hale getirmek için yapay zeka uygulamaları kullanılmaktadır [84].

Diş çürüklerinin teşhis etmek amacıyla yapay zeka destekli farklı eğitim setleri ve algoritmalar kullanılarak çeşitli sistemler geliştirilmiştir. Park ve arkadaşlarının çalışmasında intraoral fotoğraflar kullanılarak bir derin öğrenme modeli geliştirilmiş ve çürükleri %86,7 doğrulukla tespit edebildiği bildirilmiştir [110]. Kühnisch ve arkadaşlarının intraoral fotoğraflar ile eğitilen ESA kullanılarak geliştirdiği sistemin çürük tespiti doğruluğu %92,5 olarak ölçülmüştür [111]. Ayhan ve arkadaşlarının bite-wing radyografileri üzerinden geliştirdiği yapay zeka sistemi, diş ve diş çürüklerinin tespitinde yüksek doğruluk göstermiştir [112]. Benzer bir şekilde bite-wing radyografiler üzerinden Williams ve arkadaşlarının yayınladığı yapay zeka destekli bir asistan çürük teşhisi doğruluğunu %71 oranında artırmıştır [113]. Amasya ve arkadaşları KIBT görüntülerinde çürük tespiti için yapay zeka destekli bir karar destek sisteminin etkinliğini değerlendirdikleri çalışmalarında doğruluk oranı %93,9 olarak elde ettiklerini rapor etmişlerdir [114].

Periapikal patolojilerin ve alveolar kemik rezorpsiyonlarının teşhis edilmesi için yapay zeka uygulamaları geliştirilmiştir. Lin ve arkadaşları, alveolar kemik kaybını tespit etmek ve kemik kaybının boyutunu ölçmek için iki farklı yapay zeka modeli geliştirmiştir [115, 116]. Endres ve arkadaşlarının çalışmasına göre, panoramik radyografiler üzerinde periapikal radyolusensileri tespit etmek için geliştirilen derin öğrenme algoritması ağız, diş ve çene cerrahisi uzmanları ile benzer başarı göstermiştir [117]. Orhan ve arkadaşlarının çalışmasında ise, yapay zeka periapikal lezyonları %92,8 doğruluk oranı ile tespit edebilmiştir [118].

Dikey kök fraktürlerinin teşhisinde de yapay zeka tabanlı modeller üzerinde çalışılmıştır. Fukuda ve arkadaşları, panoramik radyografiler üzerinde kök fraktürlerini tespit etmek için evrişimli sinir ağlarını kullandıkları çalışmalarında ve yüksek doğruluk oranları ile başarılı

sonuçlar elde etmiştir [119]. Aynı konuda, Johari ve arkadaşları, dikey kök kırıklarını tespit etmek için derin öğrenme modeli kullanarak %96,6 doğruluk oranına ulaşmıştır [120].

Yapay zeka uygulamaları, ortodontik teşhis, planlama ve tedavi takibini verimli hale getirmek için kullanılmaktadır. Radyografiler ve intraoral tarayıcılardan elde edilen veriler ile geliştirilen algoritmalar ile dişlerin ne kadar basınç altında ve nasıl hareket ettirilmesi gerektiği hesaplanarak şeffaf plak tedavileri daha verimli hale getirilmektedir. Yapay zeka destekli sistemler ile diş segmentasyonu, dijital model kaydı ve dijital ortodontik planlama yapılarak manuel model ve planlama ihtiyacını azaltmaktadır [121].

Xie ve arkadaşları tarafından yapılan bir çalışmada, ortodontik tedavi öncesinde diş çekimi gerekliliğini değerlendirmek için yapay zeka tabanlı bir matematiksel model geliştirilmiş ve bu model, %90,4 doğruluk oranıyla çekim kararlarını başarılı bir şekilde simüle etmiştir [122]. Benzer bir şekilde Jung ve arkadaşları lateral sefalometrik radyografilerden yararlanarak bir yapay zeka modeli geliştirmişler ve diş çekimi kararı vermede %93 oranında başarı göstermiştir [123].

Yapay zeka uygulamaları, ortognatik cerrahi planlaması ve sonuç takibinde kullanılmaktadır. Du ve arkadaşları, makine öğrenmesi tabanlı bir karar destek sistemi geliştirerek ortognatik cerrahiler için tedavi planlamasını otomatikleştirmişlerdir. Kullandıkları algoritmalar ile planlama süresi 30 saniyeye kadar düşürmüşler ve ortalama hata oranı maksilla için $2,15 \pm 1,24$ mm ve mandibula için $2,81 \pm 1,57$ mm olmuştur [124]. Horst ve arkadaşları çalışmalarında, geliştirilen derin öğrenme modelinin mandibular ilerletme cerrahisi sonrası yumuşak doku profilini tahmin etme konusunda ortalama hata oranı $1,0 \pm 0,6$ mm olarak bulunmuştur [125]. Jeong ve arkadaşları, ortognatik cerrahi sonrası postoperatif sonuç tahmini için bir derin öğrenme modeli geliştirmişlerdir ve bu yöntem ile maksilla, mandibula ve çene ucundaki ortalama mutlak hata maksimum 2,34 mm olacak şekilde elde edilmiştir [126].

3. GEREÇ VE YÖNTEM

3.1. Hasta Seçimi

Bu çalışma, Gazi Üniversitesi Etik Komisyonu tarafından 06.03.2024 tarih ve E-77082166-302.08.01-896970 evrak sayısı ile onaylanmış olup (Ek 1: Etik kurul onayı), Helsinki Bildirgesi etik prensiplerine uygun olarak yapıldı.

Bu çalışmada, Gazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı arşivinden, çeşitli nedenlerle kliniğe başvuran hastalara ait ve ilgili dental şikayetleri doğrultusunda ideal koşullar altında çekilmiş panoramik radyografi görüntüleri kullanıldı.

Çalışmaya dahil edilme kriterleri:

- 18-65 yaş aralığındaki bireylerin görüntüsü
- Görüntü kalitesini etkileyecek distorsiyon ya da artefakt olmayan hastaların görüntüsü
- Maksilla ve mandibulada herhangi bir tümör, kist ya da patoloji içermeyen görüntüler
- Bununla birlikte, modelin öğrenme kapasitesini ve gerçek dünyadaki uygulanabilirliğini artırmak amacıyla, panoramik radyografilerde sıkça karşılaşılan çürük dişler, dolgu restorasyonları, kök kanal tedavili dişler, kron-köprü protezleri, kırık dişler, implantlar ve implant üstü restorasyonlar gibi yapıları içeren görüntüler veri setine dahil edilmiştir

Çalışmaya dahil edilmeme kriterleri:

- 18 yaşından küçük ve 65 yaşından büyük bireylerin görüntüsü
- Büyüme geriliği, kraniyofasiyal anomalisi veya sendromu bulunan bireyler,
- Maksillofasiyal travma öyküsü olan bireylerden elde edilen panoramik radyografiler çalışma verisine dahil edilmedi.


3.2. Görüntüleme Protokolü

Bu çalışmada kullanılan tüm radyografiler aynı Sirona ORTHOPHOS XG cihazıyla (Sirona, Bensheim, Almanya), üretici firmanın talimatlarına uygun pozisyonlandırma ve ışınlama ayarlarıyla alınan görüntülerdir. Görüntüleme parametreleri; tüp voltajı 70 kVp, X-ışını tüp akımı 10 mA, tarama süresi 13 saniyedir. Arşivimizdeki panoramik radyografi görüntüleri, ideal ekran görüntüsü (çözünürlük: 1920×1080 piksel) olan NVIDIA QUADRO FX 380 ekran kartına sahip 24 inç büyüklüğündeki medikal monitörde (Philips, Luchu Hsiang, Tayvan) incelendi.

3.3. Veri Setinin Oluşturulması ve Etiketlenmesi

Çalışma veri seti, Gazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi A.D. arşivinden Ocak 2022-Temmuz 2024 tarihleri arasında ideal koşullarda alınmış, 18 ve 65 yaş arası 1920 hastaya ait panoramik radyografi görüntüsünden oluşmaktadır. Her yaş grubunda 20 erkek ve 20 kadın olmak üzere toplam 40 birey yer almakta olup, çalışma verisi bu şekilde oluşturulan toplam 48 yaş grubundan elde edilen 1920 panoramik radyografi görüntüsünden oluşmaktadır.





Panoramik radyografiler, diş çene kompleksinin yanı sıra çeşitli anatomik yapıları içermekte ve bu yapılar modele gürültü ekleyebilmektedir. Bu nedenle çalışma tasarımı öncesinde iki aşamalı bir pilot çalışma gerçekleştirilmiştir. İlk aşamada, model eğitimi için ham panoramik görüntülerden oluşan veri seti kullanılmış; ikinci aşamada ise aynı görüntülerden diş ve çene kemikleri dışındaki anatomik yapılar manuel olarak kırıldığı bir veri seti kullanılmıştır. Yapay zeka modelinin performansı her iki durumda karşılaştırılmış ve kırılmış veri seti kullanıldığında modelin daha yüksek doğruluk oranı sağladığı gözlemlenmiştir. Bu doğrultuda, modelin yalnızca dental yapıları öğrenmesini sağlamak ve gürültü etkisini azaltmak amacıyla, çalışma kapsamındaki tüm görüntüler diş arklarını ve çene kemiklerini kapsayacak şekilde standart bir boyutta kırılarak analizde kullanılmıştır. Resim 3.1, veri setinde kullanılan standart bir panoramik radyografi görüntüsünün orijinal ve kırılmış versiyonlarını göstermektedir.



Resim 3.1. Ham panoramik radyografi görüntüsü (A); diş arklarını ve çene kemiklerini içeren, modele girdi olarak kullanılan standart boyutta kırpılmış versiyonu (B).

Bireylerin kronolojik yaş bilgileri, hasta kayıt sisteminde yer alan doğum tarihleri esas alınarak hesaplandı. Hastanın kronolojik yaşı, panoramik radyografinin çekildiği tarihten hastanın sisteme kayıtlı olduğu doğum tarihi çıkarılarak hesaplandı.

Çalışmamızda panoramik radyografiler, hastaların kronolojik yaşı ve cinsiyet bilgileriyle etiketlenerek kodlanmıştır. Veri seti, bireysel yaş grupları, veri setinin tamamını oluşturan ayrı klasörler halinde düzenlenmiştir. Yaşa göre oluşturulan bu klasörlerdeki her bir görüntü dosyası, ‘Yaş_Cinsiyet (Görüntü Numarası).jpeg’ formatını takip etmektedir. Örneğin, ‘18_E (1).jpeg’ adlı dosya, 18 yaşındaki bir erkek bireye ait ilk panoramik röntgen görüntüsünü temsil etmektedir. Resim 3.2’de, eğitim veri setine ait etiketlenmiş görüntülere örnekler sunulmuştur.

Panoramik Radyografi Görüntüsü	Cinsiyet	Yaş	Etiket
	Kadın	20	20_K (10)
	Erkek	32	32_E (9)
	Kadın	44	44_K (16)
	Erkek	51	51_E (8)
	Kadın	64	64_K (8)

Resim 3.2. Veri kümesinde kullanılan etiketlenmiş görsellere örnekler

3.4. Veri Ön İşleme ve Model Hazırlığı

Derin öğrenmeye dayalı yaş tahmin modellerinin doğru şekilde çalışabilmesi için veri ön işleme adımlarının uygulanması gerekmektedir [127]. Veri ön işleme aşaması, üç temel işlemden oluşmuştur: veri temizleme, veri dönüştürme ve ardından veri artırma. Yaşa göre oluşturulan klasördeki görüntü dosya adlarında yer alan yaş ve cinsiyet bilgileri, modelin bu bilgileri tanıyıp etiketlemesi için kullanıldı. Görüntülerin model giriş boyutlarıyla uyumlu olması için tüm veriler 224×224 piksel boyutuna yeniden ölçeklendirilmiştir. Dönüştürme işlemi, görüntülerin modelin ihtiyaç duyduğu giriş formatıyla uyumlu hâle getirilmesini sağlamıştır. PyTorch kütüphanesinin Dataset sınıfı kullanılarak görüntülerden bir veri seti oluşturulmuştur. Görüntülerin okunması için OpenCV kütüphanesinden yararlanılmış; bu işlem sırasında renk formatı BGR'den RGB'ye dönüştürülmüştür. Görüntü dosyalarının yolunun belirlenmesiyle, her yaş kategorisindeki görüntülerin %80'i model eğitimi için, %20'si ise model testleri için ayrılmıştır. Grid Search yönteminde, eğitim verilerinin %10'unu model hiperparametre optimizasyonu için kullandı.

3.5. Tahmin Modelleri

Bu çalışmada, panoramik dental radyografi görüntülerinden yaş tahmini yapmak amacıyla dört farklı derin öğrenme mimarisi kullanılmıştır: MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7. Bu modellerin seçimi, mobil ve gömülü sistemlerdeki potansiyel uygulamaları destekleyen enerji verimliliği, hesaplama karmaşıklığını etkileyen parametre sayısı ve dental görüntü analizi gibi spesifik görevlerdeki kanıtlanmış yüksek doğruluk performansları göz önünde bulundurularak gerçekleştirilmiştir. Her bir modelin mimarisi ve bu çalışmadaki uygulama detayları aşağıda açıklanmıştır.

3.5.1. MobileNetV3

MobileNetV3, mobil cihazlar ve gömülü sistemler üzerinde derin öğrenme modellerinin verimli bir şekilde çalıştırılmasını mümkün kılmak amacıyla, evrişimli sinir ağı (ESA) mimarisini kullanan enerji tasarruflu ve hafif bir derin öğrenme çerçevesi olarak tasarlanmıştır [128]. MobileNetV3, nesne tanıma, yüz tanıma, sesli asistanlar ve artırılmış gerçeklik gibi çeşitli mobil uygulamalarda yaygın olarak kullanılmaktadır [129]. Serinin en güncel sürümü olan MobileNetV3, gelişmiş doğruluk oranlarını artırılmış işlem hızıyla birleştirerek, düşük güç tüketimine sahip sistemlerde dahil etkili performans göstermektedir

[128]. MobileNetV3'ün otomatik optimizasyonu Ağ Mimarisi Arama (Neural Architecture Search, NAS) yöntemiyle gerçekleştirilmektedir. NAS yöntemi, belirli görevler için en uygun model yapılarını otomatik mimari tasarım yoluyla bulmayı amaçlamaktadır [129]. MobileNetV3, NAS aracılığıyla katman genişliği, derinliği ve aktivasyon fonksiyonu seçimi gibi hiperparametreleri optimize ederek hem hesaplama gereksinimlerini azaltmakta hem de doğruluk performansını artırmaktadır [130].

3.5.2 ResNet50

ResNet (Residual Network), derin sinir ağlarında karşılaşılan gradyan sönümlenmesi (gradient vanishing) problemini çözmek amacıyla geliştirilmiştir. Geleneksel derin sinir ağlarında, ağ derinliği arttıkça gradyan değerleri sıfıra yaklaşmakta ve bu durum modelin öğrenme sürecini zorlaştırmaktadır [131]. Artık öğrenme (residual learning) metodolojisi sayesinde ResNet, bu sorunun üstesinden gelerek, derin ve dayanıklı modellerin eğitilmesini ve geliştirilmesini mümkün kılmaktadır. ResNet50, 50 katmanlı derinliği ile, görsel işleme ve makine görüşü görevlerinde en yaygın kullanılan modellerden biri haline gelmiştir [132]. Bu teknoloji; yaş tahmini, yüz tanıma, nesne tespiti, tıbbi görüntü analizi ve biyometrik sistemlerin inşası gibi uygulamalarda yaygın olarak kullanılmaktadır. Çünkü görsel özellikleri verimli şekilde öğrenebilmekte ve güçlü transfer öğrenme yetenekleri sayesinde yüksek doğruluk oranları sunmaktadır. ResNet50, klasik ESA mimarilerindeki katmandan katmana doğrudan aktarım yerine, atlamalı bağlantıları (skip connections) yoluyla bazı katmanları doğrudan birbirine bağlayarak daha etkili bir ağırlık öğrenme süreci sağlar [133]. Bu atlamalı bağlantı yapısı, derin ağ eğitiminde gradyan sönümlenmesi sorununu ortadan kaldırırken, modelin öğrenme kapasitesini koruyarak gradyan bilgilerinin daha sağlıklı yayılmasına katkıda bulunmaktadır [134].

3.5.3 DenseNet121

DenseNet121, görüntü sınıflandırma, segmentasyon ve nesne tespiti gibi görsel görevlerde yüksek doğruluk performansı sunan, 121 katmanlı DenseNet mimarisine sahip bir modeldir [135]. DenseNet121'in temel yeniliği, tüm ardışık katmanlar arasında özellik paylaşımına (feature sharing) olanak tanımasıdır; bu da bilgi aktarımını güçlendirirken, öğrenilen özelliklerin yeniden kullanımını artırmaktadır [136]. Bu yapısal özellik, parametrelerin verimli şekilde kullanılmasını sağlayarak, sınırlı veri setlerinde dahi güçlü modellerin

çalıştırılabilmesine imkân tanır. Bu mimari tasarımı sayesinde, geleneksel ESA'larında sıkça karşılaşılan "gradyan sönümlenmesi" (vanishing gradient) problemi önemli ölçüde azaltılmış ve derin modellerin kararlı bir şekilde eğitilmesi mümkün hale gelmiştir. DenseNet121'in temel yapısını Dense Block adı verilen yapılar oluşturmaktadır. DenseNet'te her katmanın çıktısı, kendisinden sonraki tüm katmanlara doğrudan bağlantılarla iletilir. Bu model tasarımı, farklı katmanları birbirine bağlayan doğrudan bağlantılar sayesinde etkili bir ağırlık öğrenme süreci sağlar [137].

3.5.4 EfficientNetB7

Her EfficientNet modeli, çözünürlük, derinlik ve genişlik ölçeklemelerini bileşik ölçekleme (compound scaling) yöntemiyle optimize etmektedir [138]. Geleneksel ESA modelleri, genellikle yalnızca derinliği veya katman genişliğini artırarak ölçeklenirken, EfficientNet, model çözünürlüğünü derinlik ve genişlik ile dengeli bir şekilde ölçekleyerek yüksek doğruluk performansı elde etmektedir [139]. Swish aktivasyon fonksiyonları ve SE blokları ile sıkıştırma işlemi gerçekleştiren EfficientNet, daha düşük parametre sayısı ile verimli bir parametre öğrenimi sağlamaktadır [140]. EfficientNetB7 mimarisinin büyük kısmı, MBConv blokları ve optimize edilmiş evrişim katmanlarından oluşmaktadır. EfficientNetB7'de, 3×3 boyutundaki standart evrişim filtresiyle birlikte batch normalization (toplu normalizasyon) uygulaması da yer almaktadır. Genişletilmiş özellik çıkarımı yapısı, modelin özellikleri etkili bir şekilde öğrenebilmesini mümkün kılmaktadır [141]. Özellik haritası boyutunun minimize edilmesi için ise global ortalama havuzlama (global average pooling) ve tam bağlantılı katman (fully connected layer) birimleri kullanılmaktadır [142].

3.6. Karşılaştırmalı Model Analizi ve Hiperparametre Optimizasyonu


Bu çalışmada, bireylerin yaşlarının panoramik radyografi görüntüleri üzerinden belirlenmesine yönelik olarak MobileNetV3, DenseNet121, ResNet50 ve EfficientNetB7 modellerinin karşılaştırmalı analizi gerçekleştirilmiştir. Karşılaştırılan her bir modelin hiperparametreleri, Grid Search yöntemi kullanılarak belirlenmiştir. Grid Search, derin öğrenme modellerinde hiperparametre optimizasyonu için kullanılan sistematik bir yöntemdir. Model tahmin başarısını artırmak ve en uygun parametre kombinasyonlarını bulmak amacıyla, önceden belirlenen hiperparametre değerleri üzerinden tüm olası

kombinasyonları dener ve en iyi sonucu veren kombinasyonu seçer. Karşılaştırılan modeller için belirlenen hiperparametre değerleri Çizelge 3.1'de sunulmuştur.

Çizelge 3.1. Kullanılan Derin Öğrenme Modellerine Ait Hiperparametre Değerleri

Modeller	Hiperparametreler
MobileNetV3	Dropout oranı: 0.3, öğrenme oranı: 0.0005, batch size: 64, optimizasyon algoritması: Adam, epochs: 15, aktivasyon fonksiyonu: Swish
ResNet50	Öğrenme oranı: 0.0003, optimizasyon algoritması: SGD, batch size: 32, dropout rate: 0.4, epochs: 20, aktivasyon fonksiyonu: ReLU
DenseNet121	Öğrenme oranı: 0.001, optimizasyon algoritması: Adam, batch size: 32, dropout rate: 0.5, epochs: 10, aktivasyon fonksiyonu: ReLU
EfficientNetB7	Dropout oranı: 0.2, öğrenme oranı: 0.0001, batch size: 16, optimizasyon algoritması: Adam, epochs: 25, aktivasyon fonksiyonu: Swish

Şekil 3.1. dental X-ray görüntülerinden bireylerin yaş tahmin sürecini modelleyen geliştirilen sistemin akış şemasını göstermektedir. Geliştirilen sistem, yaş tahmini amacıyla işlenecek dental X-ray veri setinin toplanmasıyla başlamakta ve bu veriler model girişlerine dönüştürülmektedir. Veri ön işleme aşamasında görüntüler 224×224 piksel boyutuna yeniden boyutlandırılmakta, normalize edilmekte ve RGB renk formatına dönüştürülmektedir. Veri seti eğitim, doğrulama ve test kümeleri olarak üçe ayrılmaktadır. Grid Search yöntemi, modellerde daha iyi performans sağlayacak hiperparametrelerin belirlenmesini sağlamaktadır. Öğrenme oranı (learning rate), yığın boyutu (batch size) ve dropout oranı gibi parametreler bu aşamada optimize edilmektedir. En düşük Ortalama Kare Hata (MSE) değerine sahip hiperparametre kombinasyonu belirlendikten sonra model eğitimi başlatılmaktadır. Belirlenen hiperparametrelerle MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modelleri oluşturulmuştur. Model eğitim süreçlerinin ardından, her model test veri seti üzerinde yaş tahminleri gerçekleştirmiştir. Elde edilen tahmin sonuçları, gerçek yaş değerleriyle karşılaştırılarak ortalama karesel hata (MSE), karekök ortalama karesel hata (RMSE), ortalama mutlak hata (MAE) ve açıklayıcılık katsayısı (R^2) değerleri hesaplanmıştır.



Şekil 3.1. Geliştirilen Sisteme Ait Akış Diyagramı

Deneyisel model eğitim ve test işlemleri, Intel Core i7-7700HQ işlemci, 16 GB DDR4 RAM, 6 GB NVIDIA GeForce GTX 1060 GPU ve 256 GB SSD + 1 TB HDD depolama birimine sahip MSI GE62VR 7RF Apache Pro dizüstü bilgisayarda, Windows 11 işletim sistemi kullanılarak yürütülmüştür.

3.7. Model Performansının Değerlendirilmesi

Bu çalışmada geliştirilen derin öğrenme modellerinin yaş tahmin performansı, eğitim sürecinin tamamlanmasının ardından bağımsız bir test veri seti üzerinde değerlendirilmiştir. Modelin genelleme yeteneğini ve gerçek dünya verileri üzerindeki başarısını ölçmek amacıyla, eğitim ve doğrulama aşamalarında kullanılmayan, eğitim sürecinde yer almayan, modele tamamen yabancı test görüntülerinden oluşan test veri seti kullanılmıştır. Her bir modelin (MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7) test veri seti üzerindeki tahminleri elde edilmiş ve bu tahminler, bireylerin gerçek kronolojik yaş değerleri ile karşılaştırılmıştır. Bu karşılaştırma, modelin yaş tahminindeki doğruluğunu ve hata payını

nicel olarak belirlemek için yapılmıştır. Değerlendirme süreci, modellerin klinik uygulamalardaki potansiyel kullanım alanları ve güvenilirlik düzeyini ortaya koymak amacıyla önemli bir adımdır. Model performansının değerlendirilmesinde kullanılan spesifik ölçütler, izleyen alt başlıkta açıklanmıştır.

3.8. Performans Değerlendirme Ölçütleri

Derin öğrenme alanında, özellikle sürekli değişkenlerin tahminine yönelik görevlerde, model performansının titiz bir şekilde değerlendirilmesi son derece önemlidir. Bağımlı bir değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modellemek için kullanılan istatistiksel bir yöntem olan regresyon analizi, tahmin modellerinin doğruluğunu ve güvenilirliğini niceliksel olarak değerlendirmek amacıyla çeşitli ölçütlere dayanır. Bu ölçütler, bir derin öğrenme modelinin görülmemiş verilere ne ölçüde genellenebildiği ve hangi alanlarda iyileştirme yapılabileceği konusunda kritik bilgiler sunar. Derin öğrenme modellerinin yaş tahmin performansını objektif olarak değerlendirmek amacıyla, regresyon problemlerinde yaygın olarak kullanılan MSE, RMSE, MAE, R^2 metrikleri kullanılmıştır. Bu metrikler, modellerin tahmin doğruluğunu ve verinin varyansını açıklama düzeyini göstermektedir.

MSE, regresyon analizinde yaygın olarak kullanılan bir ölçüttür ve tahmin edilen değerler ile gerçek değerler arasındaki farkların karesinin ortalamasını hesaplayarak hatanın büyüklüğünü niceliksel olarak ifade eder. Kare alma işlemi nedeniyle büyük hataların daha fazla cezalandırılması, bu ölçütü özellikle uç değerler (outlier) karşısında hassas hale getirir. Bu özelliği nedeniyle, yalnızca birkaç büyük hata bile MSE değerini anlamlı ölçüde artırabilir [143]. MSE'nin matematiksel formülü şu şekilde ifade edilir:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Burada,

- n , veri noktalarının sayısını ifade eder.
- Y_i , i . veri noktasına ait gerçek (gözlemlenen) değeri temsil eder.

- $\hat{Y}_i$, i . veri noktasına ait tahmin edilen değeri temsil eder.

RMSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karesinin ortalamasının karekökü olarak tanımlanan ve regresyon analizinde yaygın olarak kullanılan bir ölçüttür. Temelde MSE'nin karekökü alınarak elde edilen RMSE, hata değerini hedef değişkenle aynı birimlere dönüştürdüğü için, MSE'ye kıyasla daha yorumlanabilir bir ölçü sağlar [144]. RMSE'nin matematiksel formülü şu şekilde ifade edilir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Burada:

- n , veri noktalarının sayısını ifade eder.
- Y_i , i . veri noktasına ait gerçek (gözlemlenen) değeri temsil eder.
- $\hat{Y}_i$, i . veri noktasına ait model tarafından tahmin edilen değeri temsil eder.

MAE, regresyon analizinde kullanılan ve tahmin edilen değerler ile gerçek değerler arasındaki hataların yönünü dikkate almaksızın ortalama büyüklüğünü ölçen bir değerlendirme ölçütüdür. Tahminler ile gözlemler arasındaki mutlak farkların ortalaması alınarak hesaplanır. Aykırı değerlere karşı MSE'ye göre daha az hassastır ve hataların büyüklüğünü daha doğrudan bir şekilde yansıtır. MAE'nin matematiksel formülü şu şekildedir:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Burada,

- n , veri noktalarının sayısını ifade eder.
- Y_i , i . veri noktasına ait gerçek (gözlemlenen) değeri temsil eder.

- $\hat{Y}_i$, i. veri noktasına ait tahmin edilen değeri temsil eder.

R^2 , açıklayıcılık katsayısı olarak da bilinen, regresyon modelinde bağımlı değişkendeki varyansın ne kadarının bağımsız değişkenler tarafından açıklandığını gösteren istatistiksel bir ölçüttür. Modelin, gözlemlenen verileri ne ölçüde temsil edebildiğini; başka bir deyişle, model tarafından açıklanan toplam varyasyon oranını ifade eder [145]. R^2 değeri 0 ile 1 arasında değişir; 1 değeri, modelin bağımlı değişkendeki değişkenliğin tamamını açıkladığını, 0 değeri ise hiçbirini açıklayamadığını gösterir [145]. R^2 'nin matematiksel formülü şu şekildedir:

$$R^2 = 1 - \frac{SSR}{SST}$$

Burada:

- SSR (Sum of Squared Residuals): Artık kareler toplamı; yani gerçek değerler ile tahmin edilen değerler arasındaki farkların karelerinin toplamıdır.
- SST (Total Sum of Squares): Toplam kareler toplamı; yani gerçek değerler ile bu değerlerin ortalamasının farklarının karelerinin toplamıdır.

Bu metriklerin birlikte değerlendirilmesiyle, farklı derin öğrenme modellerinin yaş tahmin performansları karşılaştırılmış ve en uygun model belirlenmiştir.

4. BULGULAR

Çalışmamızda 18–65 yaş aralığındaki her tam yaş için 20 erkek ve 20 kadın bireyin görüntüsü seçildiğinden, toplam 960 erkek ve 960 kadın hastadan oluşan veri setinde cinsiyetler arası sayısal denge sağlanmıştır. Bu homojen dağılım sonucunda her iki cinsiyet grubunun da ortalama yaşı $41,5 \pm 13,7$ yıl olarak hesaplanmıştır. Hasta kayıtlarına ilişkin ayrıntılı dağılım Çizelge 4.1’de sunulmuştur.

Çizelge 4.1. Çalışma grubunun yaş-cinsiyet dağılımı

Yaş aralığı (yıl)	Erkek, n	Kadın, n	Toplam, n
18-25	160	160	320
26-35	200	200	400
36-45	200	200	400
46-55	200	200	400
56-65	200	200	400
Toplam	960	960	1920

Modellerin eğitim süreçlerinin ardından, her bir model test veri seti üzerinde yaş tahmini gerçekleştirmiştir. Elde edilen tahmin sonuçları, gerçek yaş değerleri ile karşılaştırılmış; MSE, RMSE, R^2 ve MAE metrikleri hesaplanmıştır.

Çalışmamızda ilk veri setinde standart bir panoramik radyografi görüntüsü kullanılmıştı. Bu ilk veri seti ile MAE: 4,734 yıl, MSE: 39,238, RMSE: 6,264, R^2 : 0,827 değerleri elde edilmiştir.


Modelin yalnızca ilgili dental özellikleri öğrenmesini sağlamak ve genel doğruluğu artırmak amacıyla, tüm görüntüler diş arklarını ve çene kemiklerini kapsayacak şekilde standart boyutta kırılmış ve bu görüntüler modele veri girdisi olarak verilmiştir.

MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modellerinin panoramik radyografi görüntülerinden yaş tahmini problemine yönelik karşılaştırmalı deneysel sonuçları Çizelge 4.2'de özetlenmiştir. Modellerin performanslarının görsel olarak karşılaştırılması amacıyla, kullanılan dört farklı değerlendirme parametresine (MSE, RMSE, MAE, R^2) ait sonuçlar Şekil 4.1, Şekil 4.2, Şekil 4.3 ve Şekil 4.4'te sunulmuştur.


Çizelge 4.2. Farklı Modellerin Performans Karşılaştırması

Model	MSE	RMSE	MAE	R^2
MobileNetV3	37,214	6,101	5,202	0,823
ResNet50	29,705	5,450	4,164	0,875
DenseNet121	27,998	5,291	4,105	0,882
EfficientNetB7	23,946	4,893	3,813	0,908


(MSE: Ortalama Karesel Hata, RMSE: Karekök Ortalama Karesel Hata, MAE: Ortalama Mutlak Hata, R^2 : Açıklayıcılık Katsayısı)




Şekil 4.1. MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modellerinin yaş tahmini problemine yönelik karşılaştırmalı MSE sonuçları



Şekil 4.2. MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modellerinin yaş tahmini problemine yönelik karşılaştırmalı RMSE sonuçları




Şekil 4.3. MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modellerinin yaş tahmini problemine yönelik karşılaştırmalı MAE sonuçları



Şekil 4.4. MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 modellerinin yaş tahmini problemine yönelik karşılaştırmalı R^2 sonuçları


EfficientNetB7, en düşük hata değerlerine ve 0,908 R^2 skoruna sahip olmasıyla yaş tahmininde en yüksek açıklayıcılığa sahip model olarak öne çıkmaktadır. DenseNet121, EfficientNetB7'ye oldukça yakın sonuçlar vermiştir. Ancak DenseNet121, 0,882 R^2 değeriyle EfficientNetB7'ye kıyasla biraz daha düşük bir doğruluk düzeyine sahiptir. ResNet50, DenseNet121 ve EfficientNetB7'ye göre daha yüksek hata oranlarına sahip olsa da MobileNetV3 modelinden daha iyi performans göstermiştir. İncelenen modellerin tahmin doğruluğu ve gerçek yaşa olan yakınlıkları Şekil 4.5'te yer alan grafiklerde gösterilmektedir.



Şekil 4.5. Değerlendirilen modellere ait tahmin ve gerçek yaş arasındaki ilişkiyi gösteren saçılım grafikleri. Noktalar kırmızı çizgiye ne kadar yakınsa, performans o kadar iyi olur.

EfficientNetB7, Compound Scaling yöntemiyle görüntü çözünürlüğü, model genişliği ve derinliği dengeli bir şekilde ölçeklendirerek optimize edilmiş bir performans sunmaktadır. Özellikle ayrıntılı özelliklerin belirleyici olduğu yaş tahmini gibi problemler için daha

başarılı sonuçlar vermektedir. EfficientNetB7, yaş tahmini için kritik öneme sahip kenar detayları, çene kemiği yapısı ve diş morfolojisi gibi özellikleri daha iyi ayırt edebilme kapasitesine sahiptir. Yapılan analizler sonucunda, en iyi performansı sergileyen EfficientNetB7 modelinin tahminleri incelenmiştir. EfficientNetB7 modelinin en düşük ve en yüksek tahmin hatalarına karşılık gelen panoramik radyografi görüntüleri, Resim 5.1'de gösterilmiştir.



Resim 5.1. En başarılı model olan EfficientNetB7'nin yaş tahminlerinde en düşük ve en yüksek hataya sahip olduğu örnek panoramik radyografi görüntüleri.

DenseNet121, EfficientNetB7'den sonra en yüksek performansa sahip model olarak öne çıkmaktadır. Her katmanın önceki tüm katmanlardan gelen bilgileri tekrar kullanması sayesinde, öğrenme sürecini hızlandırmakta ve daha iyi özellik çıkarımı sağlamaktadır. Yaş tahmini gibi ayrıntılı analiz gerektiren görevlerde bilgi akışının artması, daha başarılı genellemelere olanak tanımaktadır. Ancak, DenseNet121'in parametre sayısı

EfficientNetB7'ye göre daha az olduđu için modelin karmaşıklığı ve öğrenme kapasitesi bir miktar sınırlıdır.

ResNet50, DenseNet121 ve EfficientNetB7'ye kıyasla daha az parametreye ve daha az bağlantıya sahiptir. Bu durum, özellikle yaş tahmini gibi ince detayların öğrenilmesini gerektiren görevlerde modelin kritik özellikleri öğrenme kapasitesini sınırlandırabilmektedir.

MobileNetV3, hafif ve hızlı çalışacak şekilde tasarlanmış bir modeldir ve düşük parametre sayısı nedeniyle yüksek çözünürlüklü özellikleri öğrenmekte yetersiz kalabilmektedir. MobileNetV3, EfficientNetB7 ve DenseNet121 kadar geniş ve derin katman yapısına sahip olmadığından, diş yapısı ve çene kemiği detayları gibi yaş tahmini açısından önemli olan özellikleri öğrenme kapasitesi daha düşüktür.

5. TARTIŞMA

Bireyin kronolojik yaşı resmi belgelerle doğrulanamadığında yaş tayini, adli bilimler, antropoloji, arkeoloji ve özellikle diş hekimliği alanlarında kritik önem taşır. Küresel göç hareketleriyle doğum tarihini belgeleyemeyen kişi sayısının artması, hem kimliği belirsiz kalıntıların postmortem kimliklendirilmesinde hem de yaşayan bireylerin evlat edinme, cezai ehliyet, çocuk istismarı veya emeklilik gibi hukuki süreçlerinde güvenilir yaş tahminini zorunlu kılmıştır [146-148]. Kronolojik yaştan doğru belirlenmesi, adli soruşturmalarda şüpheli havuzunu daraltırken; toplu felaket ya da kazalarda iyi korunmuş kafataslarından alınan panoramik radyografiler, düşük maliyetli ve hızlı bir tanı aracı sunarak kimlik belirleme sürecini kolaylaştırır [149]. Farklı hukuki durumlara hizmet etse de adli diş hekiminin temel sorumluluğu, bireyin biyolojik yaşına ilişkin en doğru tahmini sunmaktır. Bu tahmin kronolojik yaşla tam olarak örtüşmese bile, belirsizlik aralıklarının adli otoritelere açıkça belirtilmesi koşuluyla bilimsel geçerliliğini korumaktadır [148].

Yaş tayini, adli tıp uygulamalarının yanı sıra, ortodontik tedavi planlaması, pedodonti alanında ve genel diş hekimliği pratiğinde de kritik bir öneme sahiptir [1]. Geleneksel yöntemlerde yaş tayini, dental morfolojiye dayanmaktadır. Dişlerin gelişimsel özellikleri, çocuk ve adolesanlarda yaştan güvenilir bir göstergesi olarak kabul edilmektedir [150]. Dental yaş tayini alanındaki çalışmaların büyük çoğunluğu, diş ve kemik gelişiminin hızlı ve öngörülebilir olduğu çocuk ve adolesan popülasyonlarına odaklanmaktadır [151, 152]. Bu dönemde, dişlerin sürme evreleri, kök oluşumu ve kapanması gibi belirgin morfolojik değişiklikler, yüksek doğrulukta yaş tahmini modellerinin geliştirilmesine olanak tanımaktadır. Bu dönemde gözlenen diş sürmesi, kök gelişimi ve apeks kapanması gibi morfolojik değişiklikler, kronolojik yaş ile yüksek korelasyon gösteren sistematik ve öngörülebilir evreler sunduğundan, yüksek doğrulukta yaş tahmini modellerinin geliştirilmesini mümkün kılmaktadır [153]. Yetişkin bireylerde diş ve pulpa yapısında zamanla oluşan değişikliklerin otomatik olarak tespiti ve nitelendirilmesi, pediatrik dönemdeki belirgin gelişimsel evrelere kıyasla çok daha karmaşıktır. Willmann ve arkadaşlarının çalışmasına göre, klasik dental gelişim evresi yöntemlerinin 18 yaş ve üzerindeki bireylerde ± 1 yıl sapma toleransı ile bile doğruluğun %50'nin altına düştüğü bildirilmiştir [154].

Diş gelişiminin tomurcuklanmadan kök apekslerinin kapanmasına kadar olan sürecini yaşla ilişkilendirmeye yönelik olarak geliştirilen evrelendirme tekniklerinde, evreler açıkça tanımlanmış olsa da uzman gözlemciler tarafından panoramik radyograflar üzerinden yapılan manuel değerlendirmeler zaman alıcı olmanın yanında, gözlemciler arası ve gözlemci içi farklılığa da yol açmaktadır.[155]. Veri biliminin sürekli ilerlemesiyle birlikte, derin öğrenme yöntemleri klinik tıp ve görüntüleme araştırmalarında uygulanmaya başlanmış ve bu alanlarda uzman düzeyinde ya da daha yüksek doğruluk oranları elde edildiği bildirilmiştir [9, 12].

Buna karşılık, yetişkinlere yönelik yaş tahmini çalışmaları sayıca daha azdır ve başarı düzeyleri göreceli olarak düşük kalmaktadır. Bu durum, yetişkinlerde diş oluşumunun tamamlanmış olması ve yaşlanmaya bağlı değişikliklerin (örneğin, sekonder dentin birikimi, pulpa boşluğunun daralması, diş aşınması) bireyler arasında daha değişken olması gibi metodolojik ve biyolojik zorluklardan kaynaklanmaktadır [153, 156]. Yetişkinlerde yaşla birlikte gözlenen değişiklikler genellikle sekonder dentin birikimi, pulpa boşluğunun daralması gibi daha zor tespit edilebilen ve sübjektif işaretlerdir [151]. Bu nedenle yetişkinlerde yaşla birlikte dental yapılarda meydana gelen değişiklikleri 2D veya 3D radyografik görüntüler üzerinden ölçerek, diş ve pulpa boyutları arasındaki oranlara dayalı yaş tahmini yapılmasına yönelik çok sayıda farklı metot geliştirilmiştir [60, 62, 157-161]. Ancak bu yöntemlerin genellikle sağlıklı ve yapısal olarak değişmemiş dişler üzerinde uygulanabiliyor olması hem yöntemlerin uygulanabilirliğini sınırlamakta hem de popülasyon geneline uygulanabilirliğini güçleştirmektedir. Son yıllarda bu kısıtlılıkları aşmak amacıyla yapay zeka tabanlı yaklaşımlar ön plana çıkmış ve panoramik radyografi gibi yaygın kullanılan görüntüleme yöntemlerinden otomatik yaş tahminine yönelik çalışmalar hız kazanmıştır. Özellikle yasal reşitlik yaşının belirlenmesi gibi kritik durumlarda, geleneksel yöntemlerin sınırlılıkları yapay zeka tabanlı yenilikçi yaklaşımların önemini artırmaktadır [14, 162].

Yapay zeka yöntemleri ile otomatik ve veriye dayalı çözümler sunulabilmesi sayesinde, hızlı, nesnel ve yüksek doğruluklu tahminler büyük önem kazanmıştır [163]. Yapay zeka teknolojileri, panoramik dental radyografi görüntülerinden bireylere ait yaş tahminlerinin hesaplanmasını mümkün kılmıştır [13, 164]. Derin öğrenme modelleri, yetişkinlerdeki bu incelikli yaşlanma belirtilerini geleneksel yöntemlerden daha etkili bir şekilde yakalayarak, daha nesnel ve doğru tahminler sunma potansiyeli taşımaktadır [9]. Literatürde, yetişkin

bireylere ait panoramik radyografileri üzerinden yapay zeka yöntemini kullanılarak yaşı belirlemeye yönelik çalışmalar oldukça sınırlıdır [10]. Bu nedenle bu tez çalışmasında, yetişkin popülasyona odaklanarak, geniş çaplı bir örneklem boyutu ile yapay zeka yöntemleri kullanılmış, yaş tespitinin yapılması ile adli ve klinik uygulamalar için literatüre katkı sağlamak hedeflenmiştir. Örneklem boyutu geniş tutularak ve her yaş grubu için yeterli sayıda veri dahil edilmesi ile çalışmanın sonuçlarının daha güvenilir ve uygulanabilir kılınması amaçlanmıştır.

5.1. Makine Öğrenmesine Yönelik Çalışmalar

Makine öğrenmesi sistemleri, mevcut verilerden anlamlı çıkarımlar yaparak belirli problemlere en uygun çözümleri bulmayı hedefleyen, yapay zekanın bir alt dalıdır. [165]. Makine öğrenmesi, yüksek boyutlu verilerle çalışabilme kapasitesi sayesinde sınıflandırma, regresyon ve kümeleme gibi görevlerde etkili bir şekilde kullanılmaktadır. Geçmiş verilere dayalı öğrenme ve büyük veri kümelerindeki örüntüleri tanıma becerisi, elde edilen sonuçların tekrarlanabilirliğini artırmaktadır. Bu özellikleri nedeniyle, görüntü sınıflandırma, ses ve görüntü tanıma gibi çeşitli alanlarda yaygın biçimde kullanılmaktadır [166]. Özellikle yaş tahmini gibi sürekli değerlerin tahmin edildiği problemlerde, makine öğrenmesi kapsamında regresyon modelleri sıklıkla kullanılmaktadır. Bu modeller, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi analiz ederek, bilinen verilerden yola çıkarak bilinmeyen değerlerin tahmin edilmesini sağlar [167].

Literatürde makine öğrenmesine dayalı dental yaş tahmini çalışmaları mevcuttur. Galibourg ve arkadaşları [168], 2021 yılında 2–24 yaş aralığındaki 3605 bireye ait panoramik radyografi görüntüsü ile on farklı makine öğrenmesi algoritmasını, Demirjian ve Willems metodu gibi klasik referans yöntemleri ile karşılaştırmışlardır. Çalışmalarının sonuçları kullanılan tüm makine öğrenmesi algoritmalarının manuel formüllere kıyasla daha düşük hata ve daha tutarlı performans sağladığını göstermiş ve böylece veri odaklı modellerin popülasyona uyarlanabilir olduğu ve klasik metotlara güçlü bir alternatif olabileceği vurgulanmıştır [168]. Lee ve arkadaşları [169], 2022 yılında yaşları 11-69 arasında olan Koreli 471 bireye ait panoramik radyograflardan ölçülen 18 radyomorfometrik parametre (pulpa alanı, kanal–kret mesafesi, diş sayısı, implant sayısı vb.) ile yaş grubu sınıflandırmasını gerçekleştirmek üzere beş makine-öğrenimi modelini karşılaştırmışlardır

Çalışmalarında kronolojik yaş tahmini yerine yaş aralığı tahmin edilmeye çalışılmıştır. Araştırmacılar hem lineer hem de non-lineer yaklaşımlarla otomatik, yorumlanabilir ve klinik adli kullanıma uygun bir yaş grubu tahmin modeli sunduklarını rapor etmişlerdir [169].

Shen ve arkadaşları [170], 2021 yılında Cameriere'nin kök apeks ölçümlerini makine öğrenmesiyle birleştirerek çocuklarda (5-13 yaş arası) diş yaşını klasik formülden daha kesin biçimde tahmin etmek için 356 kadın ve 392 erkek bireye ait toplam 748 panoramik radyografiyi değerlendirmişlerdir. Kullanılan yöntemdeki parametreler cinsiyet değişkeni üç farklı makine öğrenmesi algoritması ile eğitilmiştir. Araştırmacılar sonuçların Cameriere yöntemiyle uyumlu olduğunu ve hata oranlarında belirgin bir düşüş olduğunu belirtmişlerdir [170]. Shen ve arkadaşları [171], 2023 yılında adli olgularda 16 yaş sınırını belirlemek için panoramik radyografilerde üçüncü moların gelişim evresi (Demirjian-3M), üçüncü molar olgunluk indeksi (I3M) ve ikinci moların periodontal ligament görünürlüğü (PL2M) ölçütlerini cinsiyetle birlikte 6 farklı makine öğrenimi modelini kullandılar. Çalışmalarında klasik radyolojik indekslerin makine öğrenimiyle bütünleştirilmesinin 16 yaş ceza sorumluluğu sınırında güçlü bir adli destek sağlayabileceğini vurgulamışlardır [171].

Literatürde, yaş tahmini amacıyla geliştirilen makine öğrenmesi tabanlı çalışmalarda genellikle belirli dişlere ait morfometrik ölçümlerden elde edilen sınırlı sayıda parametre kullanılmış; ya doğrudan yaş grubu sınıflandırması yapılmış ya da klasik indekslerle bütünleştirilen yarı otomatik modeller sunulmuştur [135–138]. Makine öğrenmesi prensibi ile yapılan çalışmalar veri seti oluşturulurken manuel ölçüme dayalı, operatör etkisine açık yapıdadır. Ayrıca çalışmaların kapsamı genellikle çocuk ve genç erişkin popülasyona odaklı iken bizim çalışmamız sadece yetişkin bireylere yöneliktir. Çalışmamızda makine öğrenmesini tercih etmememizin temel gerekçesi, manuel seçilen birkaç ölçütün yetişkinlerde görülen karmaşık morfolojik varyasyonu yeterince temsil edememekte ve model performansını sınırlamaktadır. Buna karşılık bizim çalışmamızda herhangi bir diş seçimi ya da manuel ölçüm gerektirmeden, panoramik radyografi görüntülerinden otomatik özellik çıkarımı yapabilen dört farklı derin öğrenme mimarisi (MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7) kullanılmış ve tam otomatik yaş tahmini gerçekleştirilmiştir. Derin öğrenme; yüksek boyutlu piksel verisindeki ince desenleri kendiliğinden öğrenerek diş seçimi gerektirmeden operatör bağımlılığını ortadan kaldırarak geniş veri hacminde doğruluğu artırır [8-11]. Çalışmamızda önerilen derin öğrenme

yaklaşımı, tam otomatik yapısı sayesinde, klinik ve adli uygulamalarda pratik ve güvenilir bir karar destek aracı olma potansiyeli taşımaktadır.

5.2. Makine Öğrenme ve Derin Öğrenme Hibrit Çalışma

Son dönemde makine ve derin öğrenme tekniklerini birleştirerek yaş tahmininde yüksek doğruluk sağlamayı hedefleyen hibrit yaklaşımlar rapor edilmiştir [15]. Bu çalışmalardan Sharifonnasabi ve arkadaşları (2022), 15–23 yaş aralığındaki 1922 panoramik radyografi görüntüsü kullanarak evrişimli sinir ağları ve makine öğrenme algoritmalarının bir arada olduğu hibrit bir model geliştirmişlerdir [15]. Çalışmalarında kullanılan hibrit modelin performansını artırmak için görüntü ön işleme sürecinden geçirerek yaşları önceden belirlenen kategorilere ayıran komşuluk tabanlı sınıflandırma stratejisi kullanmışlardır. Çalışmamızda ise 18–65 yaş aralığındaki erişkin bireylere ait panoramik radyografi görüntüleri manuel dış seçimi ya da ölçüm gerektirmeden dört farklı evrişimli sinir ağı mimarisiyle kronolojik yaşı doğrudan yıl cinsinden öngören tam otomatik bir derin öğrenme regresyon modeli kullanılmıştır. Sharifonnasabi ve arkadaşlarının [15] veri setindeki karma-daimi dentisyon geçişine ait belirgin biyolojik göstergeler model başarısını artırmış görünse de dentisyonun tamamlandığı ve yaşa bağlı radyografik değişimlerin belirsizleştiği yetişkin popülasyonda doğruluk elde etmek daha zordur; bu nedenle iki çalışmanın yöntem ve hedef popülasyon farkları doğrudan karşılaştırmayı sınırlamaktadır.

5.3. Derin Öğrenme Modelleri ile Yapılan Çalışmalar

Son yıllarda derin öğrenme teknikleri, panoramik radyografilere ilişkin görevlerin otomatikleştirilmesinde yaygın biçimde kullanılmakta olup, bu yöntemler radyografilere özellikleri otomatik olarak çıkararak; dental bölge segmentasyonu, dişlerin tespiti ve sınıflandırılması, önceki tedavilerin saptanması, hatalı konumlandırılmış panoramik radyografi görüntülerinin yeniden oluşturulması ile osteoporoz ve çene tümörlerinin tanımlanması gibi çeşitli amaçlar için kullanılmaktadır [8]. Literatürde, yaş tahmini amacıyla da son yıllarda, panoramik radyografler kullanılarak, farklı derin öğrenme modelleri üzerinde çalışılmıştır [12].

Literatürde panoramik radyografilere yaş tahmini yapılan çalışmaları incelendiğinde yaş aralıkları bakımından üç ana gruba ayrılmaktadır. Birinci grubu diş gelişiminin halen sürdüğü çocukluk ve adolesan dönemine (≤ 20 –25 yaş) odaklanmış çalışmalar

oluşturmaktadır [15, 163, 172]. Bu çalışmalarda; kök oluşumu, apeks kapanması ve diş sürmesi gibi morfolojik değişikliklerin kendine özgü, evre bazlı modellerini kullanarak ay ölçeğinde hata değerleri (MAE <1 yıl) elde edilmiştir [15, 163, 172].

Çocuklarda diş gelişimi kalıtsal olarak belirlenen, gelişimsel evreler dizisini takip ettiğinden yaş belirlemek görece daha kolaydır; bu nedenle çocuk yaş grubuna odaklı çalışmalarda ortalama hataların ay ölçeğinde kalması beklenen bir durumdur [37].

İkinci gruptaki çalışmalarda ise çocukluktan ileri yaş grubuna kadar çok daha geniş bir yaş aralığını (örneğin 3-96,5 yaş aralığı) içeren panoramik radyografiler üzerinde modeller eğitilmiştir [8, 9, 11, 149, 164, 173-177]. Bu geniş yaş aralığındaki çalışmalarda dikkat çeken ortak özellik, veri setlerinin çocuk ve adolesan bireyler lehine dengesiz bir dağılıma sahip olmasıdır. Vila-Blanco ve arkadaşlarının [8] çalışmasında 4,5-19 yaş aralığındaki bireyler toplam veri setinin %60'ından fazlasını oluşturmaktadır. Benzer şekilde, Fan ve arkadaşlarının [177] 16-50 yaş aralığında çalışmış ancak örneklerin %60'ının ≤19 yaş grubunda yoğunlaştığı dengesiz bir dağılım kullanmışlardır. Bu durum, morfolojik belirteçlerin daha belirgin olduğu küçük yaş gruplarının sayıca baskın olması nedeniyle, ortalama mutlak hata değerlerinin daha düşük değerlere ulaşılmasını kolaylaştırdığı düşünülmektedir.

Üçüncü ve son grupta ise bizim çalışmamıza benzer şekilde yalnızca erişkin popülasyona odaklanan çalışmalardır [10]. Bizim bilgilerimiz dahilinde derin öğrenme mimarilerini kullanarak yetişkin bireylerde yaş tayinin belirlenmesine yönelik sadece bir çalışma mevcuttur [10]. Erişkin bireylerde yaş tahmini, diş gelişiminin tamamlanmış olması ve yaşlanmaya bağlı değişikliklerin (sekonder dentin birikimi, pulpa boşluğunun daralması, diş aşınması) bireyler arasında daha değişken ve karmaşık olması nedeniyle metodolojik ve biyolojik olarak zordur [153, 156]. Yetişkin dentisyonda yapıların yaşa bağlı değişkenliği azaldığından, morfolojik işaretlerin keskin olduğu çocukluk dönemine kıyasla yaş tahmini daha zorlu bir problem haline gelmektedir. Ayrıca, yaş ilerledikçe biriken dış kaynaklı hasarlar, dental müdahaleler, çürük, aşınma ve kemik rezorpsiyonu gibi faktörler, yaş göstergelerini zayıflatabilir veya ortadan kaldırabilir, bu da ileri yaş gruplarında tahmin hatasını artırır [10].

Bizim çalışmamızın veri seti, 18–65 yaş aralığındaki yetişkin bireylerden oluşmaktadır. Ayrıca mevcut çalışmalardan [8-11, 149, 164, 178] farklı olarak oluşturulan veri seti homojen olarak temsil edilmiş, her yaş ve cinsiyet grubu için eşit sayıda örneklem kullanılarak veri setinin dengeli yapısı sağlanmıştır. Bu bağlamda, çalışmamızın yalnızca erişkin popülasyona odaklanması ve homojen veri dağılımıyla $MAE = 3,81$ yıl ve $R^2 = 0,908$ değerlerine ulaşması, erişkin yaş gruplarında da güvenilir tahminler yapılabileceğini göstermekte ve literatürdeki bu önemli boşluğu doldurmaktadır. Örneklem yaş dağılımının homojenitesi, sonuçların genellenebilirliği açısından kritik öneme sahip olduğunu düşünmekteyiz. Dengesiz veri setlerinde örneklem büyüklüğüne duyarlı metriklerin yanıltıcı sonuçlar üretme riski bulunmaktadır ve bu durum modelin erişkin yaşlardaki görece zayıf performansını maskeleye potansiyeli taşımaktadır.

Derin öğrenme temelli yaş tahmini çalışmaları; diş gelişim evrelerinin tespit edilmesi [12, 13, 179, 180] ya da belirli yaş eşiklerinin belirlenmesi [14, 162, 172, 181-183] gibi sınıflandırma odaklı yaklaşımların yanı sıra, kronolojik yaşı yıl cinsinden öngören regresyon tabanlı çalışmaları da kapsamaktadır.

Literatürde, diş gelişiminin evrelendirilmesine yönelik yapılan çalışmalarda çoğunlukla mandibular üçüncü molarların gelişim evrelerinin otomatik olarak belirlenmesi amaçlanmış ya da Demirjian metodu gibi diş gelişim evrelendirme sistemine göre yaşı tespit edilmeye çalışan yöntemlerin derin öğrenme modelleriyle performansları değerlendirilmiştir. De Tobel ve arkadaşları [184], modifiye Demirjian şemasına göre 10 evreye ayrılmış mandibular sol üçüncü molarları sınıflandırmak üzere AlexNet mimarisiyle transfer öğrenme yaklaşımı kullandıkları pilot çalışmalarında, insan gözlemcilerle yüksek uyumlu sonuçlar elde ettiklerini bildirmişlerdir. Boedi ve arkadaşları [179], dişin çevresine çizilen sınırlayıcı kutuların modele olumsuz etkilerini minimize etmek amacıyla üç farklı segmentasyon stratejisi denemiş; tam segmentasyon uyguladıkları DenseNet-201 mimarisinde Tobel ve arkadaşlarının çalışmasına [184] kıyasla evreleme doğruluğunu artırdıklarını ve dişe odaklı segmentasyonun performans açısından belirleyici olduğunu savunmuşlardır [179]. Benzer şekilde Banar ve arkadaşları, tamamen yapay zekaya dayalı üç adımlı bir sistem geliştirerek konumlama, segmentasyon ve evre tahmini adımlarını ESA mimarileriyle gerçekleştirmişler, otomatik sistemlerin manuel yöntemlere göre daha hızlı olmasına karşın doğruluk açısından daha sınırlı performans gösterdiklerini bildirmişlerdir [185]. Kokomoto ve arkadaşları, pedodontik ve ortodontik kullanımı hedefleyen diş

germlerinin tespitine dayanan iki aşamalı çalışmalarında, ilk olarak Scaled-YOLOv4 ile diş germlerini tespit etmiş, ardından EfficientNetV2-M ile evreleri sınıflandırarak yaklaşık üç aya karşılık gelen düşük hata payı ($MAE = 0,261$ yıl) ile dental yaş tahmini gerçekleştirmişlerdir [13]. Ong ve arkadaşları [12], Demirjian yönteminin tüm aşamalarını otomatikleştirmek amacıyla, algılama, segmentasyon ve sınıflandırma için YOLOv5, U-Net ve EfficientNet-B7 mimarilerini bir arada kullandıkları üç aşamalı otomatik evreleme sistemleriyle yüksek doğruluk elde etmiş; özellikle segmentasyon adımıyla %97,8 başarı bildirmişlerdir. Shi ve arkadaşları [186] da benzer şekilde üç aşamalı bir sistem tanımlamış; 673 panoramik radyografiden oluşan veri setinde YOLOv3 ile diş numaralandırması, ResNetXt-50 ile evrelendirme ve son olarak tespit edilen evrelerden kronolojik yaş hesaplanmış ve MAE 0,72 yıl olarak elde edilmiştir. Milani ve arkadaşları [180], 6624 mandibular üçüncü molar görüntüsünden oluşan geniş veri seti üzerinde, ön işleme filtreleri ile desteklenmiş EfficientNet mimarisi kullanarak Demirjian evrelerini %83,7 doğrulukla sınıflandıran tam otomatik bir sistem geliştirmiştir. Çalışmalarında sadece gelişim evresi sınıflandırması yapılmış; bu evrelerin kronolojik yaş ile korelasyonu için ileri çalışmalar önerilmiştir [180]. Matthijs ve arkadaşları ise beş farklı mandibular sol dişi kapsayan çalışmalarlarıyla 1639 görüntüden oluşan dengeli bir veri seti oluşturmuş, en yüksek doğruluğun birinci molarda, en düşük doğruluğun ise kesici dişlerde olduğunu; bu farkın dişlerin anatomik netliğinden kaynaklandığını bildirmişlerdir [155].

Literatürde yer alan bu çalışmaların hedef yaş grupları ile değerlendirme kriterleri, çalışmamızdan farklılık göstermektedir. Diş gelişiminin evrelendirilmesine yönelik yapılan bu çalışmalarda, kronolojik yaşın sayısal olarak tahmin edilmesi yerine, görsel sınıflandırma teknikleri kullanılarak önceden tanımlanmış diş gelişim evrelerinin saptanması amaçlanmıştır. Dolayısıyla model çıktıları, bizim çalışmamızdan farklı olarak bir yaş değerini değil diş germlerinin gelişim aşaması veya Demirjian gibi klasik yaş tayini yöntemlerine ait evreler olup doğrudan bir yaş değeri elde edilmemektedir. Nihai yaş bilgisine ulaşmak için bu evreler ya geleneksel formüllerle ya da ek regresyon modelleriyle dönüştürülmek zorundadır.

Daimi dentisyonun henüz tamamlanmadığı genç bireylerde, gelişim evrelerine dayalı yaş tahmini yöntemleri faydalı sonuçlar verebilmektedir. Söz konusu çalışmaların ortak amacı, manuel yöntemlerin sınırlılıklarını azaltarak dental yaş tahminine daha nesnel, hızlı ve tekrarlanabilir bir yaklaşım sunmaktır. Buna karşılık, bizim çalışmamız doğrudan yetişkin

bireylerde sayısal yaş tahminine odaklanmakta; bu bağlamda, daimi diş gelişiminin tamamlandığı bireylerde gelişim evrelerinin değişkenlik göstermemesi nedeniyle farklı bir metodolojik yaklaşım benimsenmektedir.

Literatürde yaş tahmini için derin öğrenme algoritmalarını kullanan bazı çalışmalarda, kritik yaş eşiklerinin (örneğin 16, 18 veya 21 yaş sınırlarının) otomatik olarak belirlenmesi hedeflenmiştir [14, 162, 172, 182]. Bu çalışmalar, yapay zeka yöntemlerinin yasal yaş eşiklerinin belirlenmesinde manuel yöntemlere kıyasla daha yüksek doğruluk sağlayabildiğini göstermektedir. Guo ve arkadaşları, Demirjian metoduyla yapılan değerlendirmeler ile CNN tabanlı modelleri karşılaştırdıkları çalışmalarında, manuel yöntemin %80–85 doğruluk oranına karşın CNN'lerin %95,9'a ulaşan doğruluk sağladığını bildirmiştir [14]. Ayrıca Grad-CAM analizleri ile modellerin pulpa boşluğu, periodontal membran aralığı gibi dişin farklı morfolojik özelliklerini dikkate aldığını ortaya koymuşlardır [14]. Benzer şekilde Murray ve arkadaşları, reşitlik yaşının belirlenmesine yönelik derin öğrenme modellerinin geleneksel yöntemlere göre %14,8 daha yüksek doğruluk oranları gösterdiğini rapor etmiştir [162]. Kim ve arkadaşları, panoramik radyograflardan elde edilen birinci molar diş görüntülerini kullanarak veri setini yaşlarına göre üç gruba ve beş gruba ayırarak performanslarını kıyaslamışlar ve ResNet-152 modeli, uzman değerlendirmesinin %10 üzerinde bir doğrulukla, %89–90 başarı oranına ulaşmıştır [183]. Ayrıca, Grad-CAM analizleri sonucunda modelin yalnızca klasik indikatörler ile sınırlı kalmayıp pulpa, alveolar kemik seviyesi ve interdental boşluk gibi bölgeleri de dikkate aldığı rapor edilmiştir [183]. Patil ve arkadaşları [172], 12–25 yaş arası bireylerin mandibular ikinci ve üçüncü molar kök uzunluklarını temel alarak hem klasik makine öğrenimi algoritmaları hem de yapay sinir ağı ile yaş tahmini yaptıkları çalışmalarında özellikle sağ üçüncü moların mesial kök uzunluğunun güçlü bir prediktör olduğunu bildirmişlerdir. Araştırmacılar, kök uzunluklarının ölçümleriyle bile 18 yaş eşiğinin güvenilir biçimde ayırt edilebileceğini belirtmişlerdir [172]. Kahm ve arkadaşları [181] ise, 5–90 yaş arası geniş veri setinde iki farklı ESA modelinin performansını değerlendirmişlerdir. İlk aşamada, her tam yıl için ayrı yaş sınıflandırması yaparak modeli eğitmişler ve bu yaklaşımda yaklaşık %31 doğruluk oranı elde etmişlerdir. İkinci aşamada ise yaşlar beşer yıllık gruplar hâlinde yeniden kategorize edilerek ± 3 yıl hata toleransı uygulanmış; bu yöntemle doğruluk oranı %73,23'e yükseldiği raporlanmıştır [181]. Kim ve arkadaşları [187], 2023 yılında, kesin kronolojik yaş bilgisi bulunmayan panoramik radyograflerde

bireyleri onlu yaş gruplarına ayırarak sınıflandırmak amacıyla bir ESA mimarisi geliştirmişler ve tahmin hatalarının daha çok komşu gruplarda yoğunlaştığını ve yaş ilerledikçe dental indikatörlerin azaldığı sonucuna varmışlardır [187]. Bui ve arkadaşları [182], 2023 yılında üçüncü molar olgunluk indeksi (I3M) ölçümünü otomatikleştirmek amacıyla bir yapay zeka temelli karar destek sistemi geliştirmiştir. Fransa ve Uganda'dan elde edilen panoramik görüntüler üzerinde yapılan çalışmada, U-Net segmentasyon modeliyle başarılı sonuçlar elde edilmiş ve ardından topolojik analiz yöntemleriyle I3M değeri hesaplanmıştır. Geliştirilen sistemin, uzman ölçümleriyle %95 düzeyinde uyum gösterdiği ve reşitlik değerlendirmelerinde güvenilir bir alternatif sunabileceği bildirilmiştir [182].

Yapılan bu çalışmaların yapısı, yaştan belirli bir eşik altında ya da üstünde olup olmadığını tespit etmeye yönelik sınıflandırma problemlerini çözmeye dayalıdır. Literatürdeki bu eşik odaklı çalışmalar, yapay zekâ ile 16, 18 veya 21 yaş gibi kritik sınırları ayırtırmayı hedefleyen sınıflandırma modelleri geliştirirken, bizim çalışmamız panoramik radyografilerden 18–65 yaş aralığında kronolojik yaştan yıl cinsinden doğrudan regresyonunu amaçlamaktadır. Bu yöntemsel ayrım, değerlendirme metriklerine de yansır: eşik çalışmalar başarıyı genellikle “doğruluk” ya da “AUC” ile rapor ederken, bizim çalışmada ise MAE (Ortalama Mutlak Hata) ve R^2 (belirleyicilik/açıklayıcılık katsayısı) gibi sürekli hata ölçütleri kullanarak model yeterliliğini sürekli hata ölçütleriyle değerlendirmektedir. Ayrıca eşik modellerinin çoğu, dentisyon gelişiminin hâlen sürdüğü veya radyografik belirteçlerin görece belirgin olduğu çocuk-adolesan popülasyonlarında test edilmiştir. Bu durum, morfolojik işaretlerin keskin olduğu yaş pencereleri sayesinde sınıflandırma doğruluğunu artırabilir. Buna karşın, yetişkin dentisyonda yapıların yaşa bağlı değişkenliği azalır; dolayısıyla bizim modelimizin geniş erişkin aralıkta yüksek açıklayıcılık sağlaması ($R^2=0,908$), evre veya eşik temelli yaklaşımlara göre daha zorlu bir problemi çözme başarısını yansıtır.

Eşik temelli çalışmalarda kronolojik yaş, sürekli bir değer yerine “16’dan büyük/küçük” veya “18 yaş sınırının altı-üstü” gibi kategorilerle ele alındığından, yıl cinsinden kesin yaş tahmini yapan regresyon yaklaşımlarına göre çözülecek problem görece daha kolaydır. Bizim modelimiz ise her panoramik radyografiyi tam yıl değeriyle eşleştirerek 18–65 yaş aralığındaki her kronolojik yıl için aynı zorluk düzeyini sürdürür. Eşik modellerinde zorluk yalnızca sınıra çok yakın bireylerde (örneğin 17–19 yaş) artar; yaş sınırından uzaklaştıkça

(örneğin 10 veya 30 yaş) morfolojik farklar belirginleştiği için görev görece kolaylaşır. Buna karşın çalışmamızda, yetişkin bireylerde dentisyonda yaşla ilişkili anatomik değişkenliğin sınırlı olmasına rağmen $MAE = 3,81$ yıl ve $R^2 = 0,908$ değerleriyle yüksek açıklayıcılık sonuçlarına ulaşılmıştır. Nitekim Kahm ve arkadaşları [143], kronolojik yaşı doğrudan tahmin etmek yerine geniş yaş aralıklarına ayırdıklarında doğruluğun belirgin biçimde arttığını göstermiştir; buna rağmen regresyon tabanlı sistemimiz sayısal yaş değerlerini öngörerek yüksek başarı göstermiştir.

Panoramik radyografilerden yaş tahmini çalışmalarında görüntü işleme stratejileri model performansını ve genellenebilirliği doğrudan etkilemektedir. Vila-Blanco ve arkadaşları [8], Fan ve arkadaşları [177], Wang ve arkadaşları [10], Mu ve Li [179], Yeom ve arkadaşları [180], Oliveira ve arkadaşları [154], Zhang ve arkadaşları [162], Park ve arkadaşları [138] ve Bizjak & Robič [182] çalışmalarında tam panoramik radyografileri doğrudan derin öğrenme ağlarına girdi olarak vererek tam otomasyon sağlamayı amaçlamışlardır. Bu sayede zaman maliyeti açısından avantaj elde edilmiştir. Bu tür tam otomatik sistemler, literatürde belirtildiği üzere, uzman tarafından seçilmiş belirli diş veya kemik bölgelerine bağımlı kalmaksızın, görüntünün tamamındaki karmaşık desenlerden yararlanarak yaş tahmini gerçekleştirmektedir [181]. Bu durum, modelin insan gözünün fark edemeyeceği veya yorumlamakta zorlanacağı detayları yakalayabilmesine olanak sağlar [7].

Bu yaklaşımlar, servikal vertebra hayalet görüntüleri veya anatomik süperpozisyonlar gibi artefakt kaynaklı hatalar nedeniyle hatalı öğrenme riskini taşımaktadır. Buna karşın, bu dezavantajı azaltmak amacıyla bazı çalışmalar panoramik radyografileri önce segmentasyon adımlarından geçirerek odaklanmış bir veri setiyle model eğitimi gerçekleştirmiştir. Aljameel ve arkadaşları [153] mandibular sol yedi diş kırparak ve Vila-Blanco ile arkadaşları [174] ESA kullanarak kanin-premolar-molar diş bölgelerini otomatik segmente ederek artefakt etkisini azaltmayı amaçlamışlardır.

Milošević ve arkadaşları [163] ise panoramik radyografi görüntüleri için diş, kemik ve tek diş maskeleri ile ablasyon deneyleri gerçekleştirmişlerdir. Bu amaçla panoramik radyografileri; dişleri içeren tüm bölgenin maskelendiği yalnızca kemik dokusunun görüntülendiği (1), dişler hariç diğer bölgelerinin maskelendiği sadece dişlerin görülebildiği (2) ve her dişin ayrı ayrı maskelendiği (3) üç farklı eğitim seti oluşturulmuştur. Tam panoramik görüntüler kullanıldığında model $MAE = 3,96$ yıl ve $R^2 = 0,844$ değerine

ulaşılmıştır. Yalnız diş bölgesiyle eğitilen modellerde hata 4,65 yıla çıkarken, dişlerin maskelendiği yalnız kemik görüntülerinde 5 yılın üzerinde MAE değerleri elde edilmiştir. Bu sonuçlar ile diş ve mandibular kemik bilgisinin birlikte kullanılmasının doğruluk üzerinde sinerjik bir etki yarattığını vurgulanmıştır [10].

Zheng ve arkadaşları [180] ise farklı bir yaklaşımla KIBT ile elde edilen 3D radyograflar üzerinden birinci molar dişlerin pulpa odasını otomatik segmentasyonla incelediği çalışmada %87,8 doğruluk oranları ve bu hacim verisi ile kurdukları matematiksel regresyon modelinde $MAE = 7,26$ yıl olarak bulmuşlardır. Bu sistemde, görüntüleme yöntemi yüksek radyasyon dozu gerektirirken, bizim çalışmamız yalnızca daha düşük doz içeren panoramik radyograflardan doğrudan derin öğrenmeye dayalı tahminler sunmaktadır.

Bu tez çalışmamızda, model performansını anlamak amacıyla ve veri setinin etkinliğini değerlendirmek üzere bir pilot çalışma yapılmıştır. Çalışmamızda, ham panoramik görüntüler ile yalnızca diş ve çene kemiklerini içeren manuel kırpılmış panoramik görüntülerden oluşan iki veri seti, derin öğrenme modellerinin performansı açısından karşılaştırılmıştır. İlk veri setinde (ham panoramik radyografi görüntüleri) elde edilen sonuçlarda $MAE = 4,73$ yıl, $R^2: 0,826$ olarak hesaplanmıştır. Bu testlerde kırpılmış görüntülerin hem daha yüksek açıklayıcılık katsayısına ($R^2: 0,908$) hem de daha düşük MAE'ya (3,81 yıl) sahip olduğu gözlenmiştir. Kırpma işlemi, servikal vertebra hayalet görüntüleri ve diş süperpozisyonlarını ortadan kaldırırken, çürük, implant ve protez gibi gerçekçi klinik varyasyonları koruyarak modelin erişkin yaş tahminindeki performansını artırmıştır. Modelin hem açıklayıcılık katsayısını hem de mutlak ortalama hata değerini iyileştirdiği gözlenmiştir. Bu sonuçlar, kırpma stratejisinin homojen örneklem dağılımı ve azaltılmış gürültü sayesinde erişkin yaş tahminindeki doğruluğu anlamlı biçimde yükselttiğini göstermiştir.

Buna rağmen, maksiller sinüs ve diğer kraniyofasiyal yapıların dışlanması potansiyel bilgi kaybına yol açmakta, modelin genellenebilirliğini kısıtlayabilmektedir. Ayrıca derin öğrenme ağlarının “kara kutu” doğası, karar süreçlerinin açıklanabilirliğini azaltmaktadır [10]. Grad-CAM benzeri görselleştirme tekniklerinin regresyon modellerine uyarlanması ya da yeni açıklanabilirlik yöntemlerinin geliştirilmesi önerilmektedir [10].

Evrişimli sinir ağları özellikle görüntü ve video gibi uzamsal düzen içeren verilerin işlenmesinde yüksek başarı gösteren, ileri beslemeli yapay sinir ağlarının özel bir türüdür. Bu ağlar, klasik tam bağlantılı ağlara kıyasla çok daha az parametre ile çalışabilir çünkü yerel bağlantılar ve ağırlık paylaşımı gibi mekanizmalar sayesinde verideki önemli görsel desenleri katmanlar aracılığıyla kademeli olarak öğrenebilir. ESA'lar, kenar gibi basit özelliklerden başlayarak giderek daha karmaşık yapıları (örneğin yüzler, nesneler) otomatik olarak ayırt edebilir. Son yıllarda yapılan araştırmalar, ESA'ların sınıflandırma, nesne tanıma ve video analizi gibi birçok görevde hem doğruluk hem de verimlilik açısından öne çıktığını göstermektedir [188-190].

Derin öğrenme alanında geliştirilen ESA'lar görüntü temelli verilerdeki uzamsal örüntüleri yakalama konusundaki üstünlükleriyle öne çıkmaktadır. ESA'ları, tam bağlı katmanlı diğer ileri beslemeli ağlara nazaran, ağırlık paylaşımı ve yerel bağlantılar sayesinde hiyerarşik özellik çıkarımı yapabilen ve yüksek genelleme kapasitesine sahip derin bir Yapay Sinir Ağı (YSA) türüdür; bu mimari, ham piksel verisinden soyut ve anlamlı uzamsal özellikleri otomatik olarak öğrenme gücü sunar [95]. ESA mimarileri, LeNet [97] ile başlayan bir gelişim süreci geçirmiş, ardından AlexNet [191] ile derin ESA geniş çapta popülerlik kazanmıştır. Daha sonra ZFNet, [192] AlexNet'in mimarisinden esinlenerek görselleştirme teknikleri ve hiperparametre iyileştirmeleri geliştirmiştir. VGG [193] daha derin ve basit katman yapılarıyla, GoogLeNet/Inception [194] ise modüler Inception bloklarıyla parametre verimliliğini artırmıştır. ResNet [195] artık bağlantılarla gradyan sönümlenmesi sorununu hafifleterek çok daha derin ağların eğitilebilmesini sağlamıştır. Daha sonra DenseNet [196] ve Xception [197] gibi mimariler, özellik yeniden kullanımını ve verimliliği artırmıştır. Son dönemde ise MobileNetV2 [198] ve EfficientNet [199] gibi hafif ve verimli modeller ile NASNet [200] gibi otomatik mimari arama (Neural Architecture Search- NAS) tabanlı yaklaşımlar geliştirilerek, derin öğrenme modellerinin performansı ve uygulanabilirliği önemli ölçüde artmıştır [7, 11, 96, 165, 201]. Bu tez çalışmasında, bireylerin yaşlarının panoramik radyografi görüntüleri üzerinden belirlenmesine yönelik olarak MobileNetV3, DenseNet121, ResNet50 ve EfficientNetB7 modellerinin karşılaştırmalı analizi gerçekleştirilmiştir.

Derin öğrenme mimarilerinin karşılaştırılması, model seçiminde performans ve kaynak kullanımı arasında denge kurmayı gerektirmektedir. MobileNetV3 ve ResNet50 gibi daha hafif yapılar, düşük parametre sayıları sayesinde hız ve bellek tasarrufu sağlarken, yüksek

çözünürlüklü morfolojik detayları yakalamada sınırlı kalmış ve yaş tahmini görevinde hata potansiyelini artırmıştır [128, 129, 132]. DenseNet121, her katmanın önceki tüm katmanlardan gelen bilgileri yeniden kullanan yapısıyla öğrenme sürecini hızlandırmıştır [136]. Buna karşın, EfficientNetB7 Compound Scaling yöntemiyle çözünürlük, derinlik ve genişlik ölçeklemelerini dengeli hale getiren mimarisi [138] ile hem kenar detayları hem de çene kemiği yapısı ile diş morfolojisi gibi kritik özellikleri daha iyi ayırt ederek çalışmamızda EfficientNetB7 ile en yüksek performans ($MAE = 3,81$ yıl, $R^2 = 0,908$) değerlerine ulaşmıştır.

Mu ve Li [173], ön eğitilmiş modelleri kullanarak transfer öğrenme temelli bir yaş tahmin sistemi geliştirmiştir [173]. 12–71 yaş aralığındaki 3000 artefaksız panoramik radyografiden oluşan veri setiyle, ResNet, VGG, DenseNet ve EfficientNet mimarileri test edilmiş, en başarılı sonuç EfficientNet-B5 ile ($MAE: 2,83$ yıl; $RMSE: 4,59$) elde edilmiştir. Genç bireylerde (12–21 yaş) hata oranı düşerken, ileri yaşlarda (52–61 yaş erkeklerde) bu değer arttığı rapor edilmiştir [173]. Çalışmamızda benzer şekilde farklı derin öğrenme mimarileri karşılaştırmış, Mu ve Li'nin [173] çalışmasındaki sonuçlara benzer şekilde EfficientNet en başarılı model olmuştur. Mu ve Li'nin [173] daha düşük hata oranlarını elde etmesindeki faktörler; gelişim çağındaki bireylerin çalışmaya dahil edilmesiyle ve örneklem büyüklüğünün fazla olması ile açıklanabilir. Öte yandan, Aljameel ve arkadaşları [163], çocuk ve genç erişkinlerde yaş tahmini için yalnızca mandibular sol yedi dişi içeren kırpılmış panoramik görüntülerle bir yapay zeka modeli geliştirmiştir [163]. VGG16, ResNet50, InceptionV3, DenseNet121 ve Xception mimarileri karşılaştırılmış, en iyi sonuç Xception modeliyle elde edilmiştir. Yaş aralıkları daraldıkça doğruluğun arttığı, özellikle 6–11 yaş grubunda MAE 'nin belirgin şekilde azaldığı bildirilmiştir [163]. Bu çalışma tasarım açısından bizim çalışmamızdan farklı olup, çalışmamızda tüm diş ve çene yapıları dikkate alınırken, Aljameel ve arkadaşları [163] sadece belirli dişleri analiz etmiş olup veri dengesizliği modelin genelleme yetisini sınırlamış olabilir. Ancak çalışmamızda homojen veri dağılımına özen gösterilmiştir.

Milošević ve arkadaşları [10], yetişkin yaş grubunda kronolojik yaş tahminine odaklanan çalışmalarında öznitelik çıkarımı amacıyla farklı ESA mimarilerini değerlendirmiştir. DenseNet201, InceptionResNetV2, ResNet50, VGG16, VGG19 ve Xception ESA mimarileri transfer öğrenme yöntemiyle karşılaştırdıkları çalışmalarında en yüksek doğruluğun VGG-16 mimarisiyle sağlandığı bildirilmiştir. Yaş tahminini görüntü analizi

temelli bir regresyon problemi olarak ele alınmış ve tam panoramik görüntüler kullanıldığı modellerinde MAE 3,96 yıl ve $R^2 = 0,844$ değerinde elde edildiği rapor edilmiştir [10].

Derin öğrenme yaklaşımları, makine öğrenmesinden farklı olarak insan müdahalesine ihtiyaç duymadan, insan gözü ile fark edilemeyecek paternleri tespit edebilmekte ve bunlar arasında çıkarımlar yapabilmektedir. Derin öğrenme sistemleri, makine öğrenme algoritmalarından farklı olarak kapalı kutu sistemlerdir, bu modellerinin bir sonuca nasıl ulaştığını tam olarak açıklamak zordur. Bu nedenle bizim çalışmamızda kullanmış olduğumuz derin öğrenme modelinde modelin yaş tahmini için sonuç üretirken nasıl çıkarımlar yaptığını hangi anatomik bölgelere odaklandığı tam olarak açıklanamamaktadır. Literatürde bazı araştırmacılar derin öğrenme sistemlerinin bu kısıtlamalarının önüne geçmek için Grad-CAM analizleri, ısı haritaları gibi yöntemler geliştirmiştir [10]. Farklı çalışmalarda [8, 14, 164, 173, 183] bu yöntemler ile değerlendirilmiş ve hangi anatomik bölgelerin sonuçlar üzerinde etkili olduğu araştırılmıştır. Grad-CAM analizlerine dayanan çalışmalar, derin öğrenme modellerinin yaş tahmininde odaklandığı anatomik bölgelerin yaşa göre değiştiğini göstermiştir. Genç bireylerde (12–31 yaş) modeller ağırlıklı olarak diş yapılarına odaklanırken, orta yaş grubunda (32–51 yaş) maksiller sinüs, ileri yaşlarda (52–71 yaş) ise mandibular korpus ve angulus bölgeleri öne çıkmıştır [164]. Özellikle pulpa boşluğu, periodontal membran ve interdental alanlar gibi düşük yoğunluklu bölgeler, manuel yöntemlere göre daha iyi sonuçlar elde edilmesini sağlayan ana odak alanları olmuştur [183]. Modelin entegre gradyan haritaları, erken yaşlarda diş sürme durumu ve kalsifikasyon evrelerinin, yaşlı bireylerde ise pulpa ölçümlerinin belirleyici olduğunu göstermektedir [164]. Ayrıca model, dişsiz bireylerde bile mandibula, maksiller sinüs ve vertebra gibi yapılardan bilgi çıkararak başarılı tahminler yapabirmiştir [164]. Bu bulgular, yapay zeka modellerinin yalnızca dental yapılara değil, daha geniş bir anatomik bağlamda karar verdiğini ve insan gözlemcisine benzer klinik odaklanmalar geliştirdiğini ortaya koymaktadır.

Grad-CAM, sınıflandırma ağlarının son katmanlarındaki aktiviteyi görselleştirmek amacıyla geliştirilmiş bir yöntemdir [181]. Teorik olarak regresyon modellerine uygulanabilse de sonuçların anlamlı ve güvenilir biçimde yorumlanması mümkün değildir [10]. Çalışmamızda sınıflandırma yerine regresyon modeli kullanıldığından, bu tür ısı haritaları model çıktılarımız için doğrudan geçerli yöntemler değildir.

Literatürde yaş tahminine cinsiyet gibi ek değişkenlerin dahil edilmesinin model performansına etkisi araştırılmıştır [8]. Vila-Blanco ve arkadaşlarının [8] çalışmasında veri setine cinsiyet bilgisinin dahil edilmesinin başarıya etkisini araştırmak amacıyla aynı veri seti kullanılarak iki farklı ESA denenmiştir. Bunlardan biri tek yönlü DANet yalnızca yaş regresyonunu hedeflerken, DASNet aynı mimaride ikinci bir yol ekleyerek cinsiyete özgü öznitelikleri de yaş tahminine dolaylı biçimde dahil edilmiştir. Araştırmacılar işaretleme gerektirmeyen bu yaklaşımda, sekiz katlı çapraz doğrulamada DASNet'in tüm veri setinde $R^2 = 0,90$ ve $MAE = 2,84$ yıl elde ederek DANet'i geride bıraktığını ve cinsiyet verisinin veri setine dahil edilmesinin başarıyı artırdığını bildirmişlerdir [8].

Wang ve arkadaşları [9], çalışmalarında cinsiyet bilgisini veri setine vermeyerek modelin gerçek dünya uygulamasını artırmayı hedeflemiştir ve bu amaçla SSR-Net'ten türetilen DENSEN mimarisi kullanılmıştır. Çalışmada 3–85 yaş aralığındaki bireylere ait panoramik radyograflar üzerinde eğitim yapılmış ve model, 25 yaş üzeri grupta kademeli regresyon yapısının sağladığı avantajla diğer Bayesian CNN Net ve DANet gibi ESA tabanlı diğer yöntemlere kıyasla daha düşük bir MAE değeri (2,87 yıl) elde etmiştir [9]. Modelin başarısında, cinsiyet bilgisinden bağımsız çalışabilmesi, yaşa bağlı morfolojik ipuçlarını aşamalı olarak işlemesi ve çocuk bireylerin de dahil olduğu geniş yaş aralığına dayalı öğrenmenin etkili olduğu düşünülmektedir.

Park ve arkadaşları [149], EfficientNet-B3 mimarisiyle geliştirdikleri ForensicNet modeliyle, yaş ve cinsiyet tahminini aynı anda yüksek doğrulukla gerçekleştirdiklerini ve farklı cihazlardan elde edilen geniş ve dengeli veri seti sayesinde kullandıkları model ile yaş için $MAE = 2,93$ yıl, cinsiyet için %99,2 doğruluk değerleri sağlamıştır. Bizim çalışmamızda cinsiyet bilgisi modele dahil edilmesine rağmen bu amaçla eğitilmemiştir. Park ve arkadaşlarının [149] çalışmalarında daha düşük MAE elde etmesinin nedeni geniş örneklem büyüklüğü ve veri setinde yer alan çocuk yaş grubunun da çalışmalarına dahil edilmesiyle ilişkili olduğunu düşünüyoruz.

Bizjak ve Robič [175], 2024 yılında yayınladıkları çalışmalarında radyogramlardaki patolojiler dışlanmadan oluşturulan 4–97 yaş aralığındaki 21 007 panoramik görüntüyle eğitilen ResNet-34 tabanlı DentAge modeliyle, test setinde MAE 3,12 yıl elde edilmiş ve modelin özellikle ileri yaşlarda hata payını arttığı gösterilmiştir. Ayrıca çalışmalarında cinsiyetler arası farklılığın başarıya etkisi incelenmiş ancak bir fark tespit edilmemiştir

[175]. Çalışmamız da benzer şekilde yalnızca yetişkin grubunda çalışmasına rağmen benzer MAE değeriyle klasik yöntemlere kıyasla yüksek doğruluk sunmuştur.

Vila-Blanco ve arkadaşları [8, 178], Wang ve arkadaşları [9], Park ve arkadaşları [149], Bizjak ve Robič [175] yaptıkları çalışmalar değerlendirildiğinde bizim araştırmamızdan farklı yaş aralıklarına sahip veri setleriyle yürütüldüğünden sonuçlar doğrudan karşılaştırılamamaktadır. Çalışmalardaki çocuk-yetişkin karma popülasyonlarda rapor edilen çarpıcı doğruluk değerlerinin, özellikle <25 yaş grubunda MAE'nin 0,5-1,0 yıla kadar inebilmesinin temel nedeni örneklem bileşenleri ve biyolojik belirteç yoğunluğundan kaynaklandığını göstermektedir. Ancak bu çalışmaların [8, 9, 163, 175, 178] veri kümesinin genç bireyler lehine dengesiz bir dağılıma sahip olması, yaşlı yaş gruplarının öğrenme sürecinde yetersiz temsil edilmesine neden olmaktadır. Araştırmalar, örnek dağılımındaki bu tür dengesizliklerin tahmin edici modellerin performansını olumsuz etkileyebileceğini göstermektedir [202]. Çocuklarda yaş belirlemek görece daha kolaydır çünkü dişlerin gelişimi kalıtsal olarak belirlenen, gelişimsel evreler dizisini takip eder [45]. Bu durumu, yaş tahmini çalışmalarında rapor edilen ortalama hata değerleri ile de doğrulanmaktadır. Bu dönemi ilgilendiren çalışmalarda hatalar yıl değil, ay ölçeğinde kalmaktadır. Çocuklara yönelik en bilinen yaş tahmini araştırmalarının tamamı hata oranını 1 yılın altında bildirilmiş, bu çalışmaların çoğunda ortalama hata 0,5 yıldan daha düşük elde edilmiştir [44, 203]. Bu nedenle erişkin dönemde bu sinyaller silikleştiklerinden Vila-Blanco ve arkadaşlarının Wang ve arkadaşlarının [9] Zhang ve arkadaşlarının [11] çalışmalarda hata değerlerinin yaşla sistematik biçimde yükselmesi beklenen bir durumdur. Çalışmamızda araştırma verimizin yetişkin yaş grubuna yönelik olması ile birlikte zamanla biriken dış kaynaklı hasarlar ve dental müdahaleler süreci daha karmaşık hale getirmektedir. Bu faktörler, diş ve kemik yapılarında değişikliklere neden olarak yaş tahmininde kullanılan belirteçlerin zayıflamasına ya da tamamen ortadan kalkmasına yol açabilmektedir. Çocuk bireylerde gelişimsel biyo-belirteçlerin varlığıyla birlikte yaş tahmini çok daha kolay hale gelir; bu durum, çocuk odaklı çalışmalarda ortalama hataların düşük olmasını açıklamaktadır. Bu etki, yaşa göre tabakalı örneklem kullanılan modeller de dahil olmak üzere tanımlanan tüm model varyantlarında gözlemlenmiştir [10].

Buna karşın yalnızca yetişkin bireyleri kapsayan çalışmamızda EfficientNet-B7 mimarisiyle elde ettiğimiz 3,81 yıllık MAE, erişkin popülasyonda dahi klinik açıdan kabul edilebilir bir doğruluk seviyesi sunarak tek aşamalı ESA yaklaşımının gücünü ortaya koymuştur.

Bulgularımız, model başarısının örneklem dağılımı, cinsiyet bilgisi kullanımı, hibrit veya çoklu regresörler gibi mimari tercihlere duyarlı olduğunu [8, 9, 173, 174]; erişkin verilerde ise veri artırımı, cihaz çeşitliliği ve global-lokal özellik entegrasyonunun hatayı daha da düşürebileceğini işaret etmektedir. Nitekim Lee ve arkadaşlarının [176] çalışmasında gösterildiği üzere, veri kümesini yaş gruplarına göre sınıflandırarak her küme için ayrı regresörler geliştirmek model başarısını artırabilen bir başka strateji olarak öne çıktığı gösterilmiştir.

Bu tez çalışmasında, 1920 panoramik radyografiden oluşan veri setiyle, literatürde ESA ile yaş tahmini amacıyla yapılan Vila-Blanco ve arkadaşlarının (2020, $n = 2289$; 2022, $n=1746$) [8, 178] ve Wang ve arkadaşlarının (2022, $n = 1903$) [9] çalışmalarındaki örneklem boyutlarına yakın bir ölçek sunmaktadır. Bununla birlikte, Milošević ve arkadaşlarının (2022, $n=4035$) [10], Bizjak ve Robič (2024, $n = 21\ 007$) [175] ve Park ve arkadaşlarının (2024, $n = 13\ 200$) [149] çalışmaları daha büyük veri seti ile gerçekleştirilmiştir.

Panoramik radyografiler üzerinden yapılan yaş tahmini çalışmalarında yarı denetimli ve tam otomatik derin öğrenme yaklaşımlarının etkinliği karşılaştırılmıştır [177, 204]. Fan ve arkadaşları geliştirdiği yarı denetimli ESA mimarisıyla 16–50 yaş arasındaki 10 035 panoramik radyografide yaş ve cinsiyet tahmini gerçekleştirmiş; %95,5 cinsiyet doğruluğu ve $MAE = 2,61$ yıl değerleri elde etmiştir [177]. Han ve arkadaşları on binden fazla panoramik radyografiyi kullanarak diş yaş tahmininde insan tanımlı ölçümlerin mi yoksa uçtan uca derin öğrenme modellerinin mi daha başarılı olduğunu araştırmışlardır [204]. Geleneksel yöntemde uzmanlar diş evrelerini elle işaretleyerek regresyon formülleriyle yaş tahmini yaparken, uçtan uca derin öğrenme modeli hiçbir manuel müdahale gerektirmeden çalışmaktadır. Han ve arkadaşları, tam otomatik derin öğrenme yaklaşımı hata oranını yarı yarıya düşüğü ve işlem süresini milisaniyelere indirerek en yüksek doğruluk ve verimliliği sağladıklarını rapor etmişlerdir [204].

Güncel literatüre uygun olarak bizim çalışmamızda, alan uzmanlarının profesyonel müdahalesine gerek duymadan hızlı ve etkili değerlendirmeler sunabilecek otomatik bir yaş tahmini analiz süreci oluşturmayı ve diş ve çene yapılarına ait karmaşık anatomik özellikleri derin öğrenme modelleri aracılığıyla inceleyerek yüksek doğrulukta yaş tahminleri elde etmeyi amaçlamaktadır. Cinsiyet bilgisi, modelleme sürecinde biyolojik varyasyonun hesaba

katılmasına olanak sağlamıştır. Ayrıca bu çalışmada veri setinin doğru eğitilmesi için veri seti dengeli ve geniş kapsamlı olarak oluşturulmaya çalışılmıştır.

Literatürde, ESA modellerinde özellikle yaş–cinsiyet–cihaz değişkenlerinde dengeli ve daha büyük bir örneklem ile genelleme hatasını azaltarak tahmin doğruluğunu artırma potansiyeli taşıdığı gösterilmiştir [149]. Bununla birlikte, çalışmamızdaki veri setimiz yaş ve cinsiyet bakımından dengeli olsa da farklı panoramik cihazlardan elde edilecek daha geniş bir veri havuzuyla yapılacak ek çalışmalar, modelimizin dış geçerliliğini ve tahmin gücünü daha da artırabilir. Çalışmamızda 65 yaşın üzerindeki bireylerin veri setine dahil edilmemesi, bulguların 65 yaş üzeri popülasyonlara genellenebilirliğini kısıtlamaktadır. Derin öğrenme yaklaşımımızın regresyon temelli olması nedeniyle, Grad-CAM gibi sınıf-aktivasyon haritaları model kararlarını şeffaflaştırmakta yetersiz kalmakta, bu da modelin hangi anatomik özelliklerden öğrendiğini ayrıntılı olarak açıklamayı güçleştirmektedir. Ayrıca, ham panoramik görüntüler yerine tüm diş ve çene yapılarını içerecek şekilde kırılmış radyografilere odaklanması, modelin doğruluğunu artırmış olmakla birlikte çene kemikleri ve dişler dışında kalan anatomik bölgelerden çıkarım yapmasını engellemiştir. Gelecekte çok merkezli, çok cihazlı, yaş grubu genişletilmiş veri setleriyle yapılacak çalışmalar hem modelin dış geçerliliğini hem de adli uygulamalardaki güvenilirliğini güçlendirecektir.

6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında manuel ve kişi bazlı ölçümlerine ihtiyaç duymadan, 1920 panoramik radyografi görüntüleri üzerinden yetişkin bireylerin kronolojik yaşını tam otomatik olarak tahmin eden evrişimli sinir ağı modelleri aracılığıyla incelenerek yüksek doğrulukta tahminler elde edilmesi amaçlanmıştır. Bu doğrultuda çalışmamızda, MobileNetV3, ResNet50, DenseNet121 ve EfficientNetB7 olmak üzere dört farklı ESA modeli kullanıldı.

Çalışmamızı planlarken gerçekleştirdiğimiz pilot çalışmalar ile ham kırılmamış panoramik radyografiler ile tüm dişleri ve çene kemiklerini içerecek şekilde kırılan radyografilerin başarısını karşılaştırdık ve kırılmış görüntüleri kullanmayı tercih ettik. Ham panoramik radyografilerin kullanıldığı durumda 4,734 yıl MAE ve 0,827 R^2 olarak hesaplanırken, kırılmış radyografilerle bu değerler sırasıyla 3,813 yıl ve 0,908 olarak elde edildi. Bu tercih modelimizin başarısını artırmış olmakla birlikte ileride genişletilmiş veri seti ile yapacağımız çalışmalarda ham panoramik radyografilerin kullanılması ve başarıya etkileri incelenebilir.

Yapay zeka temelli çalışmalarda çok farklı türde makine öğrenme algoritmaları ve derin öğrenme mimarileri kullanılmaktadır. Bu çeşitlilik çalışmaların direkt olarak birbiri ile kıyaslanmasını engellemektedir. Buna rağmen geliştirilen sistemin performansı MSE, MAE, RMSE, R^2 başarı metrikleri kullanılarak ölçülmüştür. Çalışmamızın bulguları, aynı metrikleri kullanan çalışmaların sonuçları ile karşılaştırmalı olarak değerlendirilmiştir. Karşılaştırma sonuçları, yapay zeka tabanlı benzer çalışmalarda aynı performans metrikleri kullanıldığında, geliştirdiğimiz sistemin eşdeğer veya birçok durumda ise daha iyi bir performans sergilediğini göstermektedir.

EfficientNetB7, 3,813 yıl ile en düşük MAE değerine ve 0,908 R^2 skoruna sahip modeldir. En yüksek hata değeri ise 5,202 yıl MAE ve 0,823 R^2 ile MobileNetV3 modelinde görülmüştür. DenseNet121, 4,105 yıl MAE ve 0,882 R^2 ile doğruluk açısından EfficientNetB7'nin ardından ikinci sırada yer almıştır. ResNet50 ise 4,164 yıl MAE ve 0,875 R^2 değerleri ile DenseNet121 ve EfficientNetB7'ye kıyasla daha yüksek hata oranına sahip olmasına rağmen, MobileNetV3'ten daha iyi performans göstermiştir.

Bu çalışmada derin öğrenme modellerinin tercih edilmesinin temel nedeni, yetişkinlerde görülen karmaşık morfolojik varyasyonun manuel seçilen birkaç ölçütle yeterince temsil

edilememesidir. Çalışmanın bulguları, derin öğrenme yaklaşımlarının yetişkin bireylerde yaş tahmininde yüksek doğruluk potansiyeli taşıdığını göstermektedir. Özellikle, derin öğrenme modellerinin yüksek boyutlu piksel verisindeki ince desenleri kendiliğinden öğrenerek dış seçimi gerektirmeden operatör bağımlılığını ortadan kaldırması ve geniş veri hacminde doğruluğu artırması önemli bir sonuçtur. Bu nedenle, bu tez çalışmasının sonuçları yaş tayini süreçlerini hızlandıran, objektif ve güvenilir bir karar destek aracı olma potansiyeli ile adli dış hekimliği ve klinik uygulamalar açısından büyük önem taşımakta ve literatüre katkı sunmaktadır.

Önceki araştırmalarla kıyaslandığında, bu çalışma yetişkin popülasyona odaklanmasıyla farklılaşmaktadır. Literatürdeki çoğu çalışma çocuk ve genç erişkin popülasyonlarına odaklanmış veya geniş yaş aralıklarında çocuk ve adolesan bireyler lehine dengesiz veri dağılımları kullanmıştır. Bu çalışmanın, yalnızca yetişkin bireylerde yaş tayinine yönelik derin öğrenme mimarilerini kullanan sınırlı sayıdaki çalışmalardan biri olması ve bu alanda başarılı sonuçlar elde etmesi ile bulgularının literatüre katkı için önemini artırmaktadır.

Geliştirdiğimiz modelin daha geniş veri setleri ile eğitilmesiyle başarı oranının artırmasını beklemekteyiz bu nedenle veri setimizin boyutu ileri de artırarak yeni çalışmalar planlanabilir. Çalışmamızdaki model tek merkezde ve aynı cihaz kullanılarak standart hale getirilen görüntüler üzerinden yürütülmüştür. Bu durum modelin öğrenmesini ve başarısının artmasının sağlamış olabileceğini düşünmekteyiz. Ancak modelin gerçek senaryolar üzerinde uygulanabilirliğini artırmak için veri setimize farklı cihazlardan ve farklı popülasyonlardan elde edilmiş görüntüler de dahil edilebilir. Bununla birlikte veri setimizin 65 yaşın üzerindeki bireylere ait görüntüleri içermemesi çalışmamız farklı bir kısıtlaması olabilir. Daha büyük yaş gruplarının dahil edildiği yeni genişletilmiş bir veri seti sayesinde modelin kullanılma becerisinin artacağını düşünmekteyiz.

KAYNAKLAR

1. Kurniawan, A., Chusida, A., Atika, N., Gianosa, T. K., Solikhin, M. D., Margaretha, M. S., Utomo, H., Marini, M. I., Rizky, B. N., Prakoeswa, B. F. W. R., ve diğerleri. (2022). The applicable dental age estimation methods for children and adolescents in Indonesia. *International Journal of Dentistry*, 2022(1).
2. Krishan, K., Kanchan, T., ve Garg, A. K. (2015). Dental evidence in forensic identification – an overview, methodology and present status. *The Open Dentistry Journal*, 9(1).
3. Adserias-Garriga, J., Rettger, J., ve Hostetler, S. D. (2024). Principles in identification of human remains through forensic odontology. *Perspectives in Legal and Forensic Sciences*, 1(1), 10006.
4. Koçak, N. (2018). Adli diş hekimliğinde yaş tahmininde kullanılan morfolojik, biyokimyasal ve radyografik yöntemler. *Adli diş hekimliği* (s. 147-160). Ankara: Akademisyen Yayınevi.
5. Boyacıoğlu H., ve Avcu N. (2020). Dental radyograflarda yetişkinler için yaş tayini yöntemleri. *Türkiye Klinikleri Oral and Maxillofacial Radiology-Special Topics*, 6(2), 24-29.
6. Akay G., Atak N., ve Güngör K. (2018). Adli dişhekimliğinde dişler kullanılarak yapılan yaş tayini yöntemleri. *Ege Üniversitesi Diş Hekimliği Fakültesi Dergisi*, 39(2), 73-82.
7. Khanagar S. B., Albalawi F., Alshehri A., Awawdeh M., Iyer K., Alsomaie B., Aldhebaib A., Singh O. G., Alfadley A., ve Khanagar S. B. (2024). Performance of artificial intelligence models designed for automated estimation of age using dentomaxillofacial radiographs—A systematic review. *Diagnostics*, 14(11), 1079.
8. Vila-Blanco N., Carreira M. J., Varas-Quintana P., Balsa-Castro C., ve Tomas I. (2020). Deep neural networks for chronological age estimation from OPG images. *IEEE Transactions on Medical Imaging*, 39(7), 2374-2384.
9. Wang X., Liu Y., Miao X., Chen Y., Cao X., Zhang Y., Li S., ve Zhou Q. (2022). DENSEN: a convolutional neural network for estimating chronological ages from panoramic radiographs. *BMC Bioinformatics*, 23(Suppl 3), 426.
10. Milošević D., Vodanović M., Galić I., ve Subašić M. (2022). Automated estimation of chronological age from panoramic dental X-ray images using deep learning. *Expert Systems with Applications*, 189, 116038.
11. Zhang Z.-Y., Yan C.-X., Min Q.-M., Zhang Y.-X., Jing W.-F., Hou W.-X., ve Pan K.-Y. (2024). Leverage effective deep learning searching method for forensic age estimation. *Bioengineering*, 11(7), 674.
12. Ong S.-H., Kim H., Song J.-S., Shin T. J., Hyun H.-K., Jang K.-T., ve Kim Y.-J. (2024). Fully automated deep learning approach to dental development assessment in panoramic radiographs. *BMC Oral Health*, 24(1), 426.
13. Kokomoto K., Kariya R., Muranaka A., Okawa R., Nakano K., ve Nozaki K. (2024). Automatic dental age calculation from panoramic radiographs using deep learning: a two-stage approach with object detection and image classification. *BMC Oral Health*, 24(1), 143.

14. Guo Y.-C., Han M., Chi Y., Long H., Zhang D., Yang J., Yang Y., Chen T., ve Du S. (2021). Accurate age classification using manual method and deep convolutional neural network based on orthopantomogram images. *International Journal of Legal Medicine*, 135(4), 1589-1597.
15. Sharifonnasabi F., Jhanjhi N. Z., John J., Obeidy P., Band S. S., Alinejad-Rokny H., ve Baz M. (2022). Hybrid HCNN-KNN model enhances age estimation accuracy in orthopantomography. *Frontiers in Public Health*, 10, 879418.
16. Bell S. (2019). *Forensic science: an introduction to scientific and investigative techniques* (First edition). Boca Raton, FL: CRC Press.
17. Kapoor N., Sulke P., Pardeshi P., Kakad R., ve Badiye A. (2023). Introduction to forensic science. In *Textbook of Forensic Science* (ss. 41-66). Cham: Springer.
18. Senn D. R., ve Weems R. A. (2013). *Manual of forensic odontology* (First edition). Boca Raton, FL: CRC Press.
19. Shamim T., Varughese V. I., Shameena P. M., ve Sudha S. (2006). Forensic odontology—a new perspective. *Medico-Legal Update-An International Journal*, 6(1), 1-4.
20. Afsin H., Karadayi B., ve Büyük Y. (2014). Role of forensic dentistry in forensic sciences - Chapter 1: Identification of mass fatality victims and dental age estimation in forensic cases. *Turkish Journal of Forensic Medicine*, 28, 275-286.
21. Senn D. R., ve RGS R. (2010). *Forensic Dentistry* (Second edition). Boca Raton, FL: CRC Press.
22. Neculqueo-Millán J., Boikanyo M., ve Fonseca G. M. (2025). Forensic odontology in the search of dental evidence at the scene of events with incinerated victims: a scoping review. *Forensic Science, Medicine and Pathology*, 1-12.
23. Hill A. J., Lain R., ve Hewson I. (2011). Preservation of dental evidence following exposure to high temperatures. *Forensic Science International*, 205(1-3).
24. Berketa J., ve Higgins D. (2017). Stabilisation of dental structures of severely incinerated victims at disaster scenes to facilitate human identification. *Journal of Forensic and Legal Medicine*, 51.
25. Beytullah K., ve Büyük Y. (2014). Adli diş hekimliğinin adli bilimlerdeki rolü - Bölüm 1: Felaket kurbanlarının kimliklendirilmesi ve adli olaylarda dişlerden yaş tahmini. *Adli Tıp Dergisi*, 28(3), 275-286.
26. Zehtiye F. Y. (2006). Felaket kurbanlarının kimliklendirilmesi çalışmalarında dişhekimlerinin ve diş incelemelerinin önemi. *Hacettepe Dişhekimliği Fakültesi Dergisi (Clinical Dentistry and Research)*, 30(4), 77-82.
27. Shah P., Velani P. R., Lakade L., ve Dukle S. (2019). Teeth in forensics: A review. *Indian Journal of Dental Research*, 30(2), 291-299.
28. Mincer H. H., Harris E. F., ve Berryman H. E. (1993). The A.B.F.O. study of third molar development and its use as an estimator of chronological age. *Journal of Forensic Sciences*, 38(2), 379-390.
29. Franklin D. (2010). Forensic age estimation in human skeletal remains: Current concepts and future directions. *Legal Medicine*, 12(1), 1-7.

30. Scendoni R., Vázquez I. S., Ribeiro I. L. A., De Luca S., Zolotenkova G. V., Viva S., Kumagai A., ve Cameriere R. (2024). Reliability of a forensic odontology method for age-at-death estimation in adults: A Mexican case study. *Forensic Science International: Synergy*, 9, 100484.
31. Schmeling A., ve Black S. (2010). An introduction to the history of age estimation in the living. In *Age Estimation in the Living: The Practitioners Guide* (ss. 1-18). Hoboken, NJ: Wiley.
32. Acharya A. B. (2011). Age estimation in Indians using Demirjian's 8-teeth method. *Journal of Forensic Sciences*, 56(1).
33. Kringsholm B., Jakobsen J., Sejrsen B., ve Gregersen M. (2001). Unidentified bodies/skulls found in Danish waters in the period 1992–1996. *Forensic Science International*, 123(2-3).
34. Ferreira J. L., Ferreira Á. E., ve Ortega A. I. (2008). Methods for the analysis of hard dental tissues exposed to high temperatures. *Forensic Science International*, 178(2-3).
35. Cameriere R., Flores-Mir C., Mauricio F., ve Ferrante L. (2007). Effects of nutrition on timing of mineralization in teeth in a Peruvian sample by the Cameriere and Demirjian methods. *Annals of Human Biology*, 34(5).
36. Tas J. T. v. d., Elfrink M. E. C., Heijboer A. C., Rivadeneira F., Jaddoe V. W. V., Tiemeier H., Schoufour J. D., Moll H. A., Ongkosuwito E. M., Wolvius E. B., ve diğerleri. (2018). Foetal, neonatal and child vitamin D status and enamel hypomineralization. *Community Dentistry and Oral Epidemiology*, 46(4).
37. Vila-Blanco N., Varas-Quintana P., Tomás I., ve Carreira M. J. (2023). A systematic overview of dental methods for age assessment in living individuals: from traditional to artificial intelligence-based approaches. *International Journal of Legal Medicine*, 137(4).
38. Sezer B., ve Çarıkçioğlu B. (2022). Accuracy of the London Atlas, Haavikko's Method and Cameriere's European Formula of dental age estimation in Turkish children. *Legal Medicine*, 54.
39. Massler M., ve Schour I. (1941). The development of the human dentition. *Journal of the American Dental Association*, 28, 1153.
40. Ubelaker D. H. (1989). *Human skeletal remains: Excavation, analysis, interpretation*. Chicago, IL: Aldine.
41. AlQahtani S. J., Hector M. P., ve Liversidge H. M. (2010). Brief communication: The London atlas of human tooth development and eruption. *American Journal of Physical Anthropology*, 142(3), 481-490.
42. Blenkin M., ve Taylor J. (2012). Age estimation charts for a modern Australian population. *Forensic Science International*, 221(1-3), 106-112.
43. Nolla C. M. (1960). The development of the permanent teeth. *Journal of Dentistry for Children*, 27, 254-266.
44. Demirjian A., Goldstein H., ve Tanner J. M. (1973). A new system of dental age assessment. *Human Biology*, 45(2), 211-227.

45. Gleiser I., ve Hunt E. E., Jr. (1955). The permanent mandibular first molar: Its calcification, eruption and decay. *American Journal of Physical Anthropology*, 13(2), 253-283.
46. Cameriere R., Ferrante L., ve Cingolani M. (2005). Age estimation in children by measurement of open apices in teeth. *International Journal of Legal Medicine*, 120(1).
47. Gustafson G., ve Malmö D. O. (1950). Age determinations on teeth. *Journal of the American Dental Association*, 41(1), 45-54.
48. Molnar S. (1971). Human tooth wear, tooth function and cultural variability. *American Journal of Physical Anthropology*, 34(2), 175-189.
49. Mays S. (2002). The relationship between molar wear and age in an early 19th century AD archaeological human skeletal series of documented age at death. *Journal of Archaeological Science*, 29(8), 861-871.
50. Ball J. (2023). A critique of age estimation using attrition as the sole indicator. *Journal of Forensic Odonto-Stomatology*, 20(2), 38-42.
51. Solheim, T. (1990). Dental cementum apposition as an indicator of age. *Scandinavian Journal of Dental Research*, 98(6), 510-519.
52. Bada, J. L. (1985). Amino acid racemization dating of fossil bones. *Annual Review of Earth and Planetary Sciences*, 13, 241–268.
53. Bada JL, Helfman PM: Amino acid racemization dating of fossil bones. *World Archaeology* 1975, 7(2):160-173.
54. Waite, E. R., Collins, M. J., Ritz-Timme, S., Schutz, H. W., Cattaneo, C., & Borrman, H. I. M. (1999). A review of the methodological aspects of aspartic acid racemization analysis for use in forensic science. *Forensic Science International*, 103(2), 113–124. Elsevier.
55. Ren, F., Li, C., Xi, H., Wen, Y., & Huang, K. (2009). Estimation of human age according to telomere shortening in peripheral blood leukocytes of Tibetan. *The American Journal of Forensic Medicine and Pathology*, 30(3), 252–255. LWW.
56. Takasaki, T., Tsuji, A., Ikeda, N., & Ohishi, M. (2003). Age estimation in dental pulp DNA based on human telomere shortening. *International Journal of Legal Medicine*, 117(4), 232–234. Springer.
57. Spalding, K. L., Buchholz, B. A., Bergman, L.-E., Druid, H., & Frisén, J. (2005). Age written in teeth by nuclear tests. *Nature*, 437(7057), 333–334. Nature Publishing Group.
58. Martin-de las Heras, S., Valenzuela, A., Bellini, R., Salas, C., Rubiño, M., & Garcia, J. A. (2003). Objective measurement of dental color for age estimation by spectroradiometry. *Forensic Science International*, 132(1), 57–62. Elsevier.
59. Drusini, A. G. (1993). Age estimation from teeth using soft X-ray findings. *Anthropologischer Anzeiger*, 51(1), 41–46.
60. Drusini, A.G., Toso, O. (1997). The coronal pulp cavity index: a biomarker for age determination in human adults. *American Journal of Physical Anthropology*, 103(3), 353-363.

61. Cameriere, R., Ferrante, L., Cingolani, M. (2004). Variations in pulp/tooth area ratio as an indicator of age: a preliminary study. *Journal of Forensic Sciences*, 49(2), 317-319.
62. Kvaal, S.I., Kolltveit, K., Thomsen, I.O., Solheim, T. (1995). Age estimation of adults from dental radiographs. *Forensic Science International*, 74(3), 175-185..
63. Abdinian M, Katiraei M, Zahedi H, Rengo C, Soltani P, Spagnuolo G. Age Estimation Based on Pulp–Tooth Volume Ratio of Anterior Teeth in Cone-Beam Computed Tomographic Images in a Selected Population: A Cross-Sectional Study. *Applied Sciences*. 2021;11(21):9984.
64. Helmy MA, Osama M, Elhindawy MM, Mowafey B, Taalab YM, Abd ElRahman HA. Volume analysis of second molar pulp chamber using cone beam computed tomography for age estimation in Egyptian adults. *The Journal of Forensic Odonto-Stomatology*. 2020;38(3):25-32..
65. Anjani KG, Boedi RM, Sam B, Oscandar F. Dental age estimation in Indonesian adults: An investigation of the maxillary canine pulp-to-tooth volume ratio using cone-beam computed tomography. *Imaging Science in Dentistry*. 2023;53(3):221-227.
66. Vandevoort FM, Bergmans L, Van Cleynenbreugel J, Bielen DJ, Lambrechts P, Wevers M, Peirs A, Willems G. Age calculation using X-ray microfocus computed tomographical scanning of teeth: a pilot study. *Journal of Forensic Sciences*. 2004;49(4):787-790.
67. Yang F, Jacobs R, Willems G. Dental age estimation through volume matching of teeth imaged by cone-beam CT. *Forensic Science International*. 2006;159:S78-S83.
68. Someda H, Saka H, Matsunaga S, Ide Y, Nakahara K, Hirata S, Hashimoto M. Age estimation based on three-dimensional measurement of mandibular central incisors in Japanese. *Forensic Science International*. 2009;185(1-3):110-114.
69. Aboshi H, Takahashi T, Komuro T. Age estimation using microfocus X-ray computed tomography of lower premolars. *Forensic Science International*. 2010;200(1-3):35-40.
70. White SC, Pharoah MJ. Chapter 7 - Intraoral Projections. In: White SC, Pharoah MJ, editors. *Oral Radiology*. 7th ed. St. Louis (MO): Mosby; 2014. p. 91–130.
71. Mallya SM, Lurie AG. Chapter 10 - Panoramic Imaging. In: White SC, Pharoah MJ, editors. *Oral Radiology*. 7th ed. St. Louis (MO): Mosby; 2014.
72. Orhan K, Eren H. Bölüm 11: Konik Işınlı Bilgisayarlı Tomografi (KIBT). *Konvansiyonelden Dijitale Diş Hekimliğinde Radyolojinin Esasları*. İstanbul: İstanbul Medikal Yayıncılık; 2017.
73. Robb RA. The dynamic spatial reconstructor: An X-ray video-fluoroscopic CT scanner for dynamic volume imaging of moving organs. *IEEE Transactions on Medical Imaging*. 1982;1(1):22–33.
74. Orhan K. Introduction to micro-CT imaging. In: Orhan K, editor. *Micro-computed Tomography (micro-CT) in Medicine and Engineering*. Cham: Springer; 2020. p. 1–5.

75. Zainuddin MZ, Mohamad NS, Su Keng T, Mohd Yusof MYP. The applications of MicroCT in studying age-related tooth morphological change and dental age estimation: A scoping review. *Journal of Forensic Sciences*. 2023;68(6).
76. Agematsu H, Someda H, Hashimoto M, Matsunaga S, Abe S, Kim H-J, Koyama T, Naito H, Ishida R, Ide Y. Three-dimensional observation of decrease in pulp cavity volume using micro-CT: age-related change. *The Bulletin of Tokyo Dental College*. 2010;51(1):1–8.
77. Asami R, Aboshi H, Iwawaki A, Ohtaka Y, Odaka K, Abe S, Saka H. Age estimation based on the volume change in the maxillary premolar crown using micro CT. *Legal Medicine*. 2019;37:101–107.
78. Iwaka Y. Three-dimensional observation of the pulp cavity of mandibular first molars by micro-CT. *Journal of Oral Biosciences*. 2006;48(2):97–103.
79. White SC, Pharoah MJ. Chapter 14 - Other Imaging Modalities. In: White SC, Pharoah MJ, editors. *Oral Radiology*. 7th ed. St. Louis (MO): Mosby; 2014. p. 229–249.
80. Baumann P, Widek T, Merckens H, Boldt J, Petrovic A, Urschler M, Kirnbauer B, Jakse N, Scheurer E. Dental age estimation of living persons: Comparison of MRI with OPG. *Forensic Science International*. 2015;253:123–130.
81. Guo Y, Olze A, Ottow C, Schmidt S, Schulz R, Heindel W, Pfeiffer H, Vieth V, Schmelting A, Guo Y et al. Dental age estimation in living individuals using 3.0 T MRI of lower third molars. *International Journal of Legal Medicine*. 2015;129(6):1017–1025.
82. De Tobel J, Phlypo I, Fieuws S, Politis C, Verstraete KL, Thevissen PW. Forensic age estimation based on development of third molars: a staging technique for magnetic resonance imaging. *International Journal of Legal Medicine*. 2021;135:45–52.
83. Smriti K, Kodali MVRM, Kumar M, Saraf A, Madi M, Pentapati KC, K P, Chhapparwal Y, Kodali US, Gadicherla S. Magnetic resonance images for the prediction of chronological age using CCIDE. *Clinical, Cosmetic and Investigational Dentistry*. 2024;16:201–210.
84. Khanagar SB, Al-chaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, Sarode SC, Bhandi S. Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *Journal of Dental Sciences*. 2021;16(1):12–22.
85. Arf C. (1959). Makine düşünebilir mi ve nasıl düşünebilir. *Atatürk Üniversitesi-Üniversite Çalışmalarını Muhite Yayma ve Halk Eğitimi Yayınları Konferanslar Serisi*, 1:91–103.
86. Zhang M, Li J, Zhao H, Tei K, Honiden S, Jin Z. A meta reinforcement learning-based approach for self-adaptive system. In: 2021 *IEEE International Conference on Autonomic Computing and Self-Organizing Systems (ACSOS)*. IEEE; 2021. p. 1–10.
87. Russell SJ, Norvig P. *Artificial Intelligence: A Modern Approach, Third International Edition*. London: Pearson Education; 2010.

88. Singh S, Kumar R, Payra S, Singh SK. Artificial intelligence and machine learning in pharmacological research: bridging the gap between data and drug discovery. *Cureus*. 2023;15(8):e12345.
89. Dunjko V, Briegel HJ. Machine learning & artificial intelligence in the quantum domain. *arXiv preprint arXiv:1709.02779*. 2017.
90. Agatonovic-Kustrin S, Beresford R. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*. 2000;22(5):717–727.
91. Abiodun OI, Jantan A, Omolara AE, Dada KV, Mohamed NA, Arshad H. State-of-the-art in artificial neural network applications: A survey. *Heliyon*. 2018;4(11):e00938.
92. Öztemel E. *Yapay sinir ağları* (3. baskı). İstanbul: Papatya Yayıncılık; 2020.
93. Krenker A., Bešter J., Kos A. (2011). Introduction to the Artificial Neural Networks. In *Artificial Neural Networks - Methodological Advances and Biomedical Applications* (pp. 1–11). London: IntechOpen.
94. Chartrand G., Cheng P. M., Vorontsov E., Drozdal M., Turcotte S., Pal C. J., Kadoury S., Tang A. (2017). Deep learning: a primer for radiologists. *RadioGraphics*, 37(7).
95. LeCun Y., Bengio Y., Hinton G. (2015). Deep learning. *Nature*, 521(7553).
96. Krichen M. (2023). Convolutional Neural Networks: a survey. *Computers*, 12(8), 151.
97. LeCun Y., Bottou L., Bengio Y., Haffner P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
98. Doğan F., Türkoğlu İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2).
99. Demir F. B., Yılmaz E. (2021). X-ray görüntülerinden COVID-19 tespiti için derin öğrenme temelli bir yaklaşım. *Avrupa Bilim ve Teknoloji Dergisi*, (32).
100. İnik Ö., Ülker E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85–104.
101. Jarrett K., Kavukcuoglu K., Ranzato M. A., LeCun Y. (2009). What is the best multi-stage architecture for object recognition? In *2009 IEEE 12th International Conference on Computer Vision*. IEEE.
102. Shrestha A., Mahmood A. (2019). Review of deep learning algorithms and architectures. *IEEE Access*, 7, 53040–53065.
103. Kimanzi R., Kimanga P., Cherori D., Gikunda P. K. (2024). Deep learning algorithms used in intrusion detection systems – a review. *arXiv preprint arXiv:2402.17020*.
104. Wu M., Zhou J., Peng Y., Wang S., Zhang Y. (2023). Deep learning for image classification: a review. In *International Conference on Medical Imaging and Computer-Aided Diagnosis*, 352–362. Springer.

105. Gündüz G., Cedimoğlu İ. H. (2019). Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini. *Sakarya University Journal of Computer and Information Sciences*, 2(1), 9–17.
106. Aktürk S., Serbest K. (2022). Nesne tespiti için derin öğrenme kütüphanelerinin incelenmesi. *Journal of Smart Systems Research*, 3(2), 97–119.
107. Lu Z., Wang X., Chen J. (2024). AI-empowered visualization of nucleic acid testing. *Life Sciences*, 359, 123209.
108. Bindra S., Jain R. (2024). Artificial intelligence in medical science: a review. *Irish Journal of Medical Science (1971-)*, 193(3), 1419–1429.
109. Royal College of Surgeons of England. (1995). *Annals of the Royal College of Surgeons of England*, 77.
110. Park E.Y., Cho H., Kang S., Jeong S., Kim E.-K. (2022). Caries detection with tooth surface segmentation on intraoral photographic images using deep learning. *BMC Oral Health*, 22(1), 573.
111. Kühnisch J., Meyer O., Hesenius M., Hickel R., Gruhn V. (2022). Caries detection on intraoral images using artificial intelligence. *Journal of Dental Research*, 101(2), 158–165.
112. Ayhan B., Ayan E., Bayraktar Y. (2024). A novel deep learning-based perspective for tooth numbering and caries detection. *Clinical Oral Investigations*, 28(3), 178.
113. Devlin H., Williams T., Graham J., Ashley M. (2021). The ADEPT study: a comparative study of dentists' ability to detect enamel-only proximal caries in bitewing radiographs with and without the use of AssistDent artificial intelligence software. *British Dental Journal*, 231(8), 481–485.
114. Amasya H., Alkhader M., Serindere G., Futyma-Gąbka K., Aktuna Belgin C., Gusarev M., Ezhov M., Różyło-Kalinowska I., Önder M., Sanders A., et al. (2023). Evaluation of a decision support system developed with deep learning approach for detecting dental caries with cone-beam computed tomography imaging. *Diagnostics*, 13(22), 3471.
115. Lin P.L., Huang P.W., Huang P.Y., Hsu H.C. (2015). Alveolar bone-loss area localization in periodontitis radiographs based on threshold segmentation with a hybrid feature fused of intensity and the H-value of fractional Brownian motion model. *Computer Methods and Programs in Biomedicine*, 121(3), 117–126.
116. Lin P.L., Huang P.Y., Huang P.W. (2017). Automatic methods for alveolar bone loss degree measurement in periodontitis periapical radiographs. *Computer Methods and Programs in Biomedicine*, 148, 1–11.
117. Endres M.G., Hillen F., Salloumis M., Sedaghat A.R., Niehues S.M., Quatela O., Hanken H., Smeets R., Beck-Broichsitter B., Rendenbach C., et al. (2020). Development of a deep learning algorithm for periapical disease detection in dental radiographs. *Diagnostics*, 10(6), 430.
118. Orhan K., Bayrakdar I.S., Ezhov M., Kravtsov A., Özyürek T.A. (2020). Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *International Endodontic Journal*, 53(5), 680–689.

119. Fukuda, M., Inamoto, K., Shibata, N., Arijji, Y., Yanashita, Y., Kutsuna, S., Nakata, K., Katsumata, A., Fujita, H., & Arijji, E. (2020). Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiology*, 36(4), 337–343.
120. Johari, M., Esmaeili, F., Andalib, A., Garjani, S., & Saberhari, H. (2017). Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. *Dentomaxillofacial Radiology*, 46(2), 20160107
121. Ruiz, D. C., Mureşanu, S., Du, X., Elgarba, B. M., Fontenele, R. C., & Jacobs, R. (2025). Unveiling the role of artificial intelligence applied to clear aligner therapy: A scoping review. *Journal of Dentistry*, 105564.
122. Xie, X., Wang, L., & Wang, A. (2010). Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *The Angle Orthodontist*, 80(2), 262–266.
123. Jung, S.-K., & Kim, T.-W. (2016). New approach for the diagnosis of extractions with neural network machine learning. *American Journal of Orthodontics and Dentofacial Orthopedics*, 149(1), 127–133.
124. Du, W., Bi, W., Liu, Y., Zhu, Z., Tai, Y., & Luo, E. (2024). Machine learning-based decision support system for orthognathic diagnosis and treatment planning. *BMC Oral Health*, 24(1), 286.
125. Ter Horst, R., van Weert, H., Loonen, T., Bergé, S., Vinayahalingam, S., Baan, F., Maal, T., de Jong, G., & Xi, T. (2021). Three-dimensional virtual planning in mandibular advancement surgery: Soft tissue prediction based on deep learning. *Journal of Cranio-Maxillofacial Surgery*, 49(9), 775–782.
126. Jeong SH, Woo MW, Shin DS, Yeom HG, Lim HJ, Kim BC, Yun JP: Three-Dimensional Postoperative Results Prediction for Orthognathic Surgery through Deep Learning-Based Alignment Network. *Journal of Personalized Medicine* 2022, 12(6):998.
127. Lee, H., Tajmir, S., Lee, J., Zissen, M., Yeshiwas, B. A., Alkasab, T. K., Choy, G., & Do, S. (2017). Fully automated deep learning system for bone age assessment. *Journal of digital imaging*, 30(4), 427–441.
128. Cai, H., Lin, J., Lin, Y., Liu, Z., Tang, H., Wang, H., Zhu, L., & Han, S. (2022). Enable deep learning on mobile devices: Methods, systems, and applications. *ACM Transactions on Design Automation of Electronic Systems (TODAES)*, 27(3), 1–50.
129. Li, C., Yang, X., Hu, Y., Wu, S., Wang, J., & Wang, P. (2024). 3D guiding assisted augmented assembly technology with rapid object detection in dynamic environment. *Advanced Engineering Informatics*, 62, 102857.
130. Mi, J.-X., Feng, J., & Huang, K.-Y. (2022). Designing efficient convolutional neural network structure: A survey. *Neurocomputing*, 489, 139–156.
131. Wu, Z., Shen, C., & Van Den Hengel, A. (2019). Wider or deeper: Revisiting the resnet model for visual recognition. *Pattern Recognition*, 90, 119–133.
132. Shafiq, M., & Gu, Z. (2022). Deep residual learning for image recognition: A survey. *Applied Sciences*, 12(18), 8972.

133. Aanjankumar, S., Sathyamoorthy, M., Dhanaraj, R. K., Surjit Kumar, S. R., Poonkuntran, S., Khadidos, A. O., & Selvarajan, S. (2025). Prediction of malnutrition in kids by integrating ResNet-50-based deep learning technique using facial images. *Scientific Reports*, 15(1), 7871.
134. Nejad, S. M. M., Abbasi-Moghadam, D., Sharifi, A., Farmonov, N., Amankulova, K., & László, M. (2022). Multispectral crop yield prediction using 3D-convolutional neural networks and attention convolutional LSTM approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 254–266.
135. Geroski, T., Ranković, V., Pavić, O., Dašić, L., Petrović, M., Milovanović, D., & Filipović, N. (2025). Enhancing COVID-19 disease severity classification through advanced transfer learning techniques and optimal weight initialization schemes. *Biomedical Signal Processing and Control*, 100, 107103.
136. Bello, A., Ng, S.-C., & Leung, M.-F. (2024). Skin cancer classification using fine-tuned transfer learning of DENSENET-121. *Applied Sciences*, 14(17), 7707.
137. Li, B. (2022). Facial expression recognition by DenseNet-121. In *Multi-chaos, fractal and multi-fractional artificial intelligence of different complex systems* (pp. 263–276). Elsevier.
138. Lin, C., Yang, P., Wang, Q., Qiu, Z., Lv, W., & Wang, Z. (2023). Efficient and accurate compound scaling for convolutional neural networks. *Neural Networks*, 167, 787–797.
139. Atila, Ü., Uçar, M., Akyol, K., & Uçar, E. (2021). Plant leaf disease classification using EfficientNet deep learning model. *Ecological Informatics*, 61, 101182.
140. Mao, Y., Song, B., Zhang, Z., Yang, W., & Lan, Y. (2023). Multi-classification Sensitive Image Detection Method Based on Lightweight Convolutional Neural Network. *KSII Transactions on Internet & Information Systems*, 17(5).
141. Taştımur, C., & Akın, E. (2023). A Hybrid Classification Approach for Fasteners Based on Transfer Learning with Fine-Tuning and Deep Features. *Turkish Journal of Science and Technology*, 18(2), 461–475.
142. Gong, W., Chen, H., Zhang, Z., Zhang, M., & Gao, H. (2020). A data-driven-based fault diagnosis approach for electrical power DC-DC inverter by using modified convolutional neural network with global average pooling and 2-D feature image. *IEEE Access*, 8, 73677–73697.
143. Varshini, A. G. P., Kumari, K. A., Janani, D., & Soundariya, S. (2021). Comparative analysis of machine learning and deep learning algorithms for software effort estimation. In *Journal of Physics: Conference Series*, 1767(1), 012019.
144. Jadon, A., Patil, A., & Jadon, S. (2024). A comprehensive survey of regression-based loss functions for time series forecasting. In *International Conference on Data Management, Analytics & Innovation* (pp. 117–147). Springer.
145. Gao, J. (2024). R-squared (R²)--How much variation is explained? *Research Methods in Medicine & Health Sciences*, 5(4), 104–109.
146. Akay, G., Gungor, K., & Gurcan, S. (2019). The applicability of Kvaal methods and pulp/tooth volume ratio for age estimation of the Turkish adult population on cone beam computed tomography images. *Australian Journal of Forensic Sciences*, 51(3), 251–265.

147. Akay, G., Karataş, M. S., Karadağ, Ö., Gungor, K., & Üçok, C. Ö. (2020). An application for Olze's method and tooth coronal index for age estimation of a Turkish adult population. *Australian Journal of Forensic Sciences*, 52(6), 699–710.
148. Cunha, E., Baccino, E., Martrille, L., Ramsthaler, F., Prieto, J., Schuliar, Y., Lynnerup, N., & Cattaneo, C. (2009). The problem of aging human remains and living individuals: A review. *Forensic Science International*, 193(1–3), 1–13.
149. Park, S.-J., Yang, S., Kim, J.-M., Kang, J.-H., Kim, J.-E., Huh, K.-H., Lee, S.-S., Yi, W.-J., & Heo, M.-S. (2024). Automatic and robust estimation of sex and chronological age from panoramic radiographs using a multi-task deep learning network: A study on a South Korean population. *International Journal of Legal Medicine*, 138(4), 1741–1757.
150. Sinha, S., Umapathy, D., Shashikanth, M. C., Misra, N., Mehra, A., & Singh, A. K. (2014). Dental age estimation by Demirjian's and Nolla's method: A comparative study among children attending a dental college in Lucknow (UP). *Journal of Indian Academy of Oral Medicine and Radiology*, 26(3), 279–286.
151. Naeimi, S. M., Darvish, S., Salman, B. N., & Luchian, I. (2024). Artificial intelligence in adult and pediatric dentistry: A narrative review. *Bioengineering*, 11(5), 431.
152. Mohamed, E. G., Redondo, R. P. D., Koura, A., El-Mofty, M. S., & Kayed, M. (2023). Dental age estimation using deep learning: A comparative survey. *Computation*, 11(2), 18.
153. Phulari, R. G. S., & Dave, E. J. (2021). Evolution of dental age estimation methods in adults over the years from occlusal wear to more sophisticated recent techniques. *Egyptian Journal of Forensic Sciences*, 11(1).
154. Willmann, C., Fernandez De Grado, G., Kolb, C., Raul, J.-S., Musset, A.-M., Gros, C.-I., & Offner, D. (2023). Accuracy of age estimation using three dental age estimation methods in a young, large, and multiethnic patient sample. *Dentistry Journal*, 11(12), 288.
155. Matthijs, L., Delande, L., De Tobel, J., Büyükçakir, B., Claes, P., Vandermeulen, D., & Thevissen, P. (2024). Artificial intelligence and dental age estimation: Development and validation of an automated stage allocation technique on all mandibular tooth types in panoramic radiographs. *International Journal of Legal Medicine*, 138(6), 2469–2479.
156. Zaborowicz, M., Zaborowicz, K., Biedziak, B., & Garbowski, T. (2022). Deep learning neural modelling as a precise method in the assessment of the chronological age of children and adolescents using tooth and bone parameters. *Sensors*, 22(2), 637.
157. Cameriere, R., Ferrante, L., & Cingolani, M. (2004). Precision and reliability of pulp/tooth area ratio (RA) of second molar as indicator of adult age. *Journal of Forensic Sciences*, 49(6), 1319–1323.
158. Bosmans, N., Ann, P., Aly, M., & Willems, G. (2005). The application of Kvaal's dental age calculation technique on panoramic dental radiographs. *Forensic Science International*, 153(2–3).

159. Cameriere, R., Ferrante, L., Belcastro, M. G., Bonfiglioli, B., Rastelli, E., & Cingolani, M. (2007). Age estimation by pulp/tooth ratio in canines by mesial and vestibular peri-apical X-rays. *Journal of Forensic Sciences*, 52(5).
160. Drusini, A. G. (2008). The coronal pulp cavity index: A forensic tool for age determination in human adults. *Cuadernos de Medicina Forense*, 235–249.
161. Jagannathan, N., Neelakantan, P., Thiruvengadam, C., Ramani, P., Premkumar, P., Natesan, A., Herald, J. S., & Luder, H. U. (2011). Age estimation in an Indian population using pulp/tooth volume ratio of mandibular canines obtained from cone beam computed tomography. *Journal of Forensic Odontostomatology*, 29(1), 1–6.
162. Murray, J., Heng, D., Lygate, A., Porto, L., Abade, A., Manica, S., & Franco, A. (2024). Applying artificial intelligence to determination of legal age of majority from radiographic data. *Morphologie*, 108(360), 100723.
163. Aljameel, S. S., Althumairy, L., Albassam, B., Alsheikh, G., Albluwi, L., Althukair, R., Alhareky, M., Alamri, A., Alabdan, A., & Shahin, S. Y. (2023). Predictive artificial intelligence model for detecting dental age using panoramic radiograph images. *Big Data and Cognitive Computing*, 7(1), 8.
164. Oliveira, W., Albuquerque Santos, M., Burgardt, C. A. P., Anjos Pontual, M. L., & Zanchettin, C. (2024). Estimation of human age using machine learning on panoramic radiographs for Brazilian patients. *Scientific Reports*, 14(1), 1–12.
165. Niño-Sandoval, T. C., Doria-Martinez, A. M., Escobar, R. A. V., Sánchez, E. L., Rojas, I. B., Álvarez, L. C. V., Mc Cann, D. S. F., & Támara-Patiño, L. M. (2024). Efficacy of the methods of age determination using artificial intelligence in panoramic radiographs: A systematic review. *International Journal of Legal Medicine*, 138(4), 1459–1496.
166. Mohammad, N., Ahmad, R., Kurniawan, A., & Mohd Yusof, M. Y. P. (2022). Applications of contemporary artificial intelligence technology in forensic odontology as primary forensic identifier: A scoping review. *Frontiers in Artificial Intelligence*, 5, 1060892.
167. Yan, W., Renteria, C., Huang, Y., & Arola, D. D. (2021). A machine learning approach to investigate the materials science of enamel aging. *Dental Materials*, 37(12), 1761–1771.
168. Galibourg, A., Cussat-Blanc, S., Dumoncel, J., Telmon, N., Monsarrat, P., & Maret, D. (2021). Comparison of different machine learning approaches to predict dental age using Demirjian's staging approach. *International Journal of Legal Medicine*, 135(2), 665–675.
169. Lee, Y.-H., Won, J. H., Auh, Q.-S., & Noh, Y.-K. (2022). Age group prediction with panoramic radiomorphometric parameters using machine learning algorithms. *Scientific Reports*, 12(1), 11177.
170. Shen, S., Liu, Z., Wang, J., Fan, L., Ji, F., & Tao, J. (2021). Machine learning assisted Cameriere method for dental age estimation. *BMC Oral Health*, 21(1), 619.
171. Shen, S., Zhou, Z., Wang, J., Fan, L., Han, J., & Tao, J. (2023). Using machine learning to determine age over 16 based on development of third molar and periodontal ligament of second molar. *BMC Oral Health*, 23(1), 680.

172. Patil, V., Saxena, J., Vineetha, R., Paul, R., Shetty, D. K., Sharma, S., Smriti, K., Singhal, D. K., Naik, N., & Patil, V. (2023). Age assessment through root lengths of mandibular second and third permanent molars using machine learning and artificial neural networks. *Journal of Imaging*, 9(2), 33.
173. Mu CC, Li G. Age estimation using panoramic radiographs by transfer learning. *Chinese Journal of Dental Research*. 2022;25(2):117-124.
174. Yeom H-G, Lee B-D, Lee W, Lee T, Yun JP. Estimating chronological age through learning local and global features of panoramic radiographs in the Korean population. *Scientific Reports*. 2023;13(1):Article 21345.
175. Bizjak Ž, Robič T. DentAge: Deep learning for automated age prediction using panoramic dental X-ray images. *Journal of Forensic Sciences*. 2024;69(6):128–137.
176. Lee T, Shin W, Lee J-H, Lee S, Yeom H-G, Yun JP. Resolving the non-uniformity in the feature space of age estimation: A deep learning model based on feature clusters of panoramic images. *Computerized Medical Imaging and Graphics*. 2024;112:102209.
177. Fan F, Ke W, Dai X, Shi L, Liu Y, Lin Y, Cheng Z, Zhang Y, Chen H, Deng Z, et al. Semi-supervised automatic dental age and sex estimation using a hybrid transformer model. *International Journal of Legal Medicine*. 2023;137(3):705–717.
178. Vila-Blanco N, Varas-Quintana P, Aneiros-Ardao Á, Tomás I, Carreira MJ. XAS: Automatic yet explainable age and sex determination by combining imprecise per-tooth predictions. *Computers in Biology and Medicine*. 2022;149:106059.
179. Boedi RM, Banar N, Tobel JD, Bertels J, Vandermeulen D, Thevissen PW. Effect of lower third molar segmentations on automated tooth development staging using a convolutional neural network. *Journal of Forensic Sciences*. 2020;65(2):555–562.
180. Milani OH, Atici SF, Allareddy V, Ramachandran V, Ansari R, Cetin AE, Elnagar MH, et al. A fully automated classification of third molar development stages using deep learning. *Scientific Reports*. 2024;14(1):Article 10324.
181. Kahm SH, Kim J-Y, Yoo S, Bae S-M, Kang J-E, Lee SH, et al. Application of entire dental panorama image data in artificial intelligence model for age estimation. *BMC Oral Health*. 2023;23(1) 1007.
182. Bui R, Iozzino R, Richert R, Roy P, Boussel L, Tafrount C, Ducret M, et al. Artificial intelligence as a decision-making tool in forensic dentistry: A pilot study with I3M. *International Journal of Environmental Research and Public Health*. 2023;20(5):4620.
183. Kim, S., Lee, Y.-H., Noh, Y.-K., Park, F. C., & Auh, Q.-S. (2021). Age-group determination of living individuals using first molar images based on artificial intelligence. *Scientific Reports*, 11(1), 1073.
184. De Tobel J, Radesh P, Vandermeulen D, Thevissen PW. An automated technique to stage lower third molar development on panoramic radiographs for age estimation: A pilot study. *Journal of Forensic Odonto-Stomatology*. 2017;35(2):42–54.
185. Banar N, Bertels J, Laurent F, Boedi RM, De Tobel J, Thevissen P, Vandermeulen D. Towards fully automated third molar development staging in panoramic radiographs. *International Journal of Legal Medicine*. 2020;134(5):1831–1841.

186. Shi Y, Ye Z, Guo J, Tang Y, Dong W, Dai J, Miao Y, You M, et al. Deep learning methods for fully automated dental age estimation on orthopantomograms. *Clinical Oral Investigations*. 2024;28(3):1317–1328.
187. Kim YR, Choi JH, Ko J, Jung YJ, Kim B, Nam SH, Chang WD, et al. Age group classification of dental radiography without precise age information using convolutional neural networks. *Healthcare*. 2023;11(8):1068.
188. Raj, R., ve Kos, A. (2025). An extensive study of convolutional neural networks: applications in computer vision for improved robotics perceptions. *Sensors*, 25(4), 1033.
189. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., ve Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53.
190. Kavitha, M., Gayathri, R., Polat, K., Alhudhaif, A., ve Alenezi, F. (2022). Performance evaluation of deep e-CNN with integrated spatial-spectral features in hyperspectral image classification. *Measurement*, 191, 110760.
191. Krizhevsky, A., Sutskever, I., ve Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
192. Zeiler MD, Fergus R. Visualizing and understanding convolutional networks. In: *European Conference on Computer Vision*. Springer; 2014. p. 818–33.
193. Jaderberg M, Simonyan K, Zisserman A. (2015) Spatial transformer networks. *Advances in Neural Information Processing Systems* 28. 2015;28.
194. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D., (2015) Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*. p. 1–9.
195. He K, Zhang X, Ren S, Sun J. (2016) Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*. p. 770–8.
196. Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. (2017) Densely connected convolutional networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. p. 4700–8.
197. Chollet F. (2017) Xception: Deep learning with depthwise separable convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*. p. 1251–8.
198. Sandler M, Howard A, Zhu M, Zhmoginov A, Chen LC. (2018) MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE conference on computer vision and pattern recognition*. p. 4510–20.
199. Tan, M., ve Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. *International Conference on Machine Learning (ICML)*, 6105–6114.

200. Zoph B, Vasudevan V, Shlens J, Le QV. (2018) Learning transferable architectures for scalable image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*. p. 8697–710.
201. Li, Z., Liu, F., Yang, W., Peng, S., ve Zhou, J. (2021). A survey of convolutional neural networks: Analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019.
202. Shahrokh Esfahani, M., ve Dougherty, E. R. (2014). Effect of separate sampling on classification accuracy. *Bioinformatics*, 30(2), 242–250.
203. Cameriere, R., Ferrante, L., De Angelis, D., Scarpino, F., ve Galli, F. (2008). The comparison between measurement of open apices of third molars and Demirjian stages to test chronological age of over 18 year olds in living subjects. *International Journal of Legal Medicine*, 122(6), 493–497.
204. Han, M., Du, S., Ge, Y., Zhang, D., Chi, Y., Long, H., Yang, J., Yang, Y., Xin, J., ve Chen, T. (2022). With or without human interference for precise age estimation based on machine learning? *International Journal of Legal Medicine*, 136(3), 821–831.

EKLER

EK-1. Etik Kurul Onayı

Evrak Tarih ve Sayısı: 06.03.2024-E.896970



T.C.
GAZİ ÜNİVERSİTESİ REKTÖRLÜĞÜ
Etik Komisyonu



Sayı : E-77082166-302.08.01-896970
Konu : Bilimsel ve Eğitim Amaçlı

06.03.2024

Sayın Doç. Dr. Gülsün AKAY
Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Başkanlığı - Öğretim Üyesi

Tez danışmanı olduğunuz, araştırmacı grubu Gülsün AKAY ve Çağrı ERDOĞDU'dan oluşan, Üniversitemiz Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı **Arş.Gör. Çağrı ERDOĞDU'nun**, uzmanlık tez çalışması olan **"Yetişkin Bireylerde Panoramik Radyografi Görüntüleri Kullanılarak Yaşın Belirlenmesinde Derin Öğrenme Modeli "** başlıklı tez çalışması ile ilgili araştırma önerisi Komisyonumuzun **27.02.2024** tarih ve **04** sayılı toplantısında görüşülmüş olup,

Çalışmanın, yapılması planlanan yerlerden izin alınması koşuluyla yapılmasında etik açıdan bir sakınca bulunmadığına oybirliği ile karar verilmiş ve karara ilişkin imza listesi ekte gönderilmiştir.

Bilgilerinizi ve gereğini rica ederim.

Araştırma Kod No: 2024 - 326

Prof. Dr. İsmail KARAKAYA
Komisyon Başkanı

Ek:1 Liste

Belge Doğrulama Kodu :BSMRK1Z963

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Takip Adresi : <https://www.turkiye.gov.tr/gazi-universitesi-cbys>



Emniyet Mahallesi Bandırma Caddesi No :6/1 06560 Yenimahalle/ANKARA
Tel:0 (312) 202 20 57 - 0 (312) 2... Faks:0 (312) 202 38 76
İnternet Adresi :<http://etikkomisyon.gazi.edu.tr/>
Kep Adresi: gaziuniversitesi@hs01.kep.tr

Bilgi için :Nursel Güner
Genel Evrak Sorumlusu
Telefon No:202 20 57



Bu belge,güvenli elektronik imza ile imzalanmıştır.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : ERDOĞDU, Çağrı

Uyruğu : T.C.

Doğum tarihi ve yeri :

e-mail :

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Uzmanlık	Gazi Üniversitesi	2025
Lisans	Hatay Mustafa Kemal Üniversitesi	2019
Lise	İstiklal Makzume Anadolu Lisesi	2014

İş Deneyimi

Yıl	Yer	Görev
2022-halen	Gazi Üniversitesi	Araştırma Görevlisi
2020-2022	İskenderun M Tipi Kapalı ve Açık Ceza İnfaz Kurumu	Diş Hekimi

Yabancı Dil

İngilizce

Yayınlar

Science Citation Index (SCI) ve Science Citation Index-Expanded (SCI-E) kapsamında uluslararası indekslerde taranan hakemli dergilerde yayımlanan makaleler:

1. Erdoğan, Ç., ve Akay, G. (2024). Relationship between mandibular arch parameters and third molar impaction. *International Dental Journal*, 74(Suppl. 1), S64. <https://doi.org/10.1016/j.identj.2024.07.763>

Tübitak-Ulakbim tarafından taranan ulusal hakemli dergilerde yayımlanan makaleler:

1. Erdoğan, Ç., ve Akay, G. (2024). Nuclear imaging applications in dentistry. *ADO Klinik Bilimler Dergisi*, 13(3), 562–569. <https://doi.org/10.54617/adoklinikbilimler.1427368>

Sözlü Sunum Bildiriler:

1. Erdoğan, Ç., ve Akay, G. (2024, 12–15 Eylül). *Relationship between mandibular arch parameters and third molar impaction*. FDI World Dental Congress, İstanbul.
2. Erdoğan, Ç., ve Akay, G. (2025, 23-27 Nisan). *Sanal ve artırılmış gerçeklik teknolojilerinin diş hekimliği eğitimindeki yeri: Öğrenci perspektifi*. 5. Uluslararası Oral Diagnoz ve Maksillofasiyal Radyoloji Derneği Kongresi, Girne, Kıbrıs (KKTC).

Poster Sunum Bildiriler:

1. Erdoğan, Ç., Peker, İ., Akay, G., Osmanoğlu, A. T., ve İnan, S. (2022, 19–23 Ekim). *Fasiyal asimetriye neden olan periferik ossifiye fibrom: Olgu sunumu*. 4. Uluslararası Oral Diagnoz ve Maksillofasiyal Radyoloji Derneği Kongresi, İzmir.
2. Erdoğan, Ç., ve Akay, G. (2023, 5–8 Ekim). *Dilde skuamöz hücreli karsinomun erken tanısı: Bir olgu sunumu*. 2. Uluslararası Ağız Kanseri Kongresi, İzmir.
3. Nalçabasmaz, İ., Akay, G., Atik, B., ve Erdoğan, Ç. (2025, 23–27 Nisan). *Atipik yerleşimli basit kemik kisti – Olgu sunumu*. 5. Uluslararası Oral Diagnoz ve Maksillofasiyal Radyoloji Derneği Kongresi, Girne, Kıbrıs (KKTC).

Bilimsel Etkinlikler/Sertifikalar:

1. Anatomiden Patolojiye TME Görüntüleme. 4. Uluslararası Oral Diagnoz ve Maksillofasiyal Radyoloji Derneği Kongresi, İzmir, Türkiye, 19-23 Ekim 2022
2. 31. Deney Hayvanları Uygulama ve Etik Kursu. (Gazi Üniversitesi Uzaktan Eğitim Uygulama ve Araştırma Merkezi (GUZEM) ve Laboratuvar Hayvanları Yetiştirme ve Deneysel Araştırmalar Merkezi (GÜDAM) iş birliğinde düzenlenen uzaktan eğitim kurs programı) 18-28 Mart 2024/Ankara

Hobiler

Klasik Türk Müziği, Kitap Okumak, Europa Universalis 4, Powerlifting



GAZİ GELECEKTİR..

