

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

**YAPAY ZEKA ALGORİTMALARI KULLANILARAK
PANORAMİK RADYOGRAFLAR ÜZERİNDEN
BİREYLERİN DİŞ YAŞLARININ TESPİTİ**

Gülfem ÖZLÜ UÇAN

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI
UZMANLIK TEZİ

DANIŞMAN
Doç. Dr. Burak Kerem APAYDIN

DENİZLİ-2023

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

**YAPAY ZEKA ALGORİTMALARI KULLANILARAK
PANORAMİK RADYOGRAFLAR ÜZERİNDEN
BİREYLERİN DİŞ YAŞLARININ TESPİTİ**

Gülfem ÖZLÜ UÇAN

**AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI
UZMANLIK TEZİ**

**DANIŞMAN
Doç. Dr. Burak Kerem APAYDIN**

DENİZLİ-2023

PAMUKKALE ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ
UZMANLIK TEZİ ONAY FORMU

[REDACTED]

[REDACTED]

[REDACTED]

[REDACTED]

[REDACTED]

[REDACTED]

[REDACTED]

ETİK BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı beyan ederim.



TEŐEKKÜR

Öğrencisi olmanın haklı gururunu yaşadığım, akademisyenliği ve insanlığıyla kendime örnek aldığım, uzmanlık eğitimim ve tezimin her aşmasında yol göstericiliğini, hoşgörüsünü, sabrını ve desteğini esirgemeyen kıymetli danışman hocam Doç. Dr. Burak Kerem Apaydın'a saygı ve teşekkürlerimi sunarım.

Uzmanlık eğitimim boyunca, destekleri ve emekleri için değerli hocalarım Ağız, Diş ve Çene Radyolojisi anabilim dalı başkanımız Prof. Dr. Hayati Murat Akgül'e ve Dr. Öğretim Üyesi Gözde Açıkgöz'e,

Tezimin metodoloji kısmında bilgi ve tecrübesini esirgemeyen, desteğini her zaman hissettiğim hocam Prof. Dr. Osman Nuri Uçan'a ve emekleri için Dr. Murthadha Mohammed Hadi Alkadhmi ve Dr. Omar Abboosh'a,

Berber çalışmaktan büyük keyif duyduğum arkadaşlarım Dt. Ezgi Uzun, Dt. Ozan Uysal, Dt. Hasret Koşar, Dt. Şeriye Mert'e ve Elif Erdoğan'a,

Yaşarken elimizden kayıp gittiğini fark etmeden büyük bir mutlulukla geçirdiğimiz günleri tüm hayatım boyunca özlemlerle anacağım, dostluklarıyla her zaman yanımda olan en yakın arkadaşlarım Dt. Aybüke İpek Atik ve Dt. Gül Melike Güngör İlhan'a,

Sevginin yeryüzündeki tüm söylenişleri ile duygularımı kelimelere döksem bile duygularımın büyüklüğünü ifade edemeyeceğim kadar çok sevdiğim canım annem Yeşim Güngören Özlü, kıymetli babam Fahrettin Özlü, biricik kardeşim Yiğit Emir Özlü'ye ve tüm aileme,

Yuvamızda kavuşacağımız günü sabırla bekleyen, hayat yolculuğunda zorlu yokuşlardan geçerken bana çiçekli düzlükleri düşündüren ve kanatlarımdaki rüzgar olan gökyüzümün en parlak yıldızı sevgili eşim Doç. Dr. Bahadır Uçan'a,

Saygı ve sevgilerimle en içten teşekkürlerimi sunarım.

ÖZET

Amaç: Çalışmamızda, klasik yaş tahmini metotlarında görülen gözlemci öznelliğinin yaş tahminini etkilemesi, metotların çok fazla zaman ve çaba gerektiren manuel ölçümlere dayanması, örneklem büyüklükleri nedeniyle rutin klinik uygulama zorluğu gibi dezavantajların üstesinden gelmek amacıyla panoramik radyograflar üzerinden diş yaşının yapay zeka algoritmaları kullanılarak otomatik olarak tahmini amaçlanmıştır.

Yöntem: Çalışmamıza Pamukkale Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı arşivinde, 1 Mart 2020- 1 Mart 2022 tarihleri arasında panoramik radyografi bulunan, dahil edilme kriterlerini karşılayan, 6 ile 15 yaşları arasındaki tüm hastalar dahil edilmiştir. Veri setimizi oluşturan 622 bireyin panoramik radyograflarından ve hasta kayıtlarından oluşan verilerden İki Boyutlu Derin Konvolüsyonel Sinir Ağı (2D-DCNN) ve Tek Boyutlu Derin Konvolüsyonel Sinir Ağı (1D-DCNN) teknikleri kullanılarak öznitelik çıkarımı gerçekleştirilmiştir. Öznitelik bilgileri kullanılarak yaş tahmini gerçekleştirmek için ise Genetik algoritma (GA) ve Rastgele Orman algoritması (RF) modifiye edilerek birleştirilmiş ve Modifiye Genetik-Rastgele Orman Algoritması (MG-RF) olarak tanımlanmıştır. Çalışmamızda kullanılan sistemin performansı, kodun uygulanması sırasında hesaplanan MSE, MAE, RMSE ve R^2 değerine göre analiz edilmiştir.

Bulgular: Uygulanan algoritmalar sonucunda MSE değeri 0,00027, MAE değeri 0,0079, RMSE 0,0888 ve R^2 puanı 0,999 olarak tespit edilmiştir.

Sonuç: Adli bilimlerde, doğumdan ergenlik çağına kadar, tahmin edilen diş yaşı ve kronolojik yaş arasındaki kabul edilebilir farkının ± 1.00 yıl olarak bildirilmesi nedeniyle çalışmamızın yaş tespitinde etkili bir performans gösterdiği sonucuna varılabilir. Bu nedenle çalışmamızda kullanılan sistemin gelecekte adli bilimler kapsamında kullanılabilir bir nitelik taşıyabileceğini düşünmekteyiz.

Anahtar Kelimeler: yaş tahmini, diş yaşı tahmini, adli diş hekimliği, derin öğrenme, derin-CNN

ABSTRACT

Objective: In our study, we aimed to perform automatic estimation of dental age through panoramic radiographs using artificial intelligence algorithms in an attempt to overcome the such disadvantages as observer subjectivity affecting classical age estimation methods, the methods relying on time-consuming and labor-intensive manual measurements, and the challenges seen in routine clinical application due to sample sizes.

Method: In our study, all patients between the ages of 6 and 15 who had panoramic radiographs between March 1, 2020 and March 1, 2022 in the archive of Pamukkale University Faculty of Dentistry, Department of Oral, Dental and Maxillofacial Radiology were included. Feature extraction was performed based on the data consisting of panoramic radiographs and patient records of the 622 individuals in our dataset using Two-Dimensional Deep Convolutional Neural Network (2D-DCNN) and One-Dimensional Deep Convolutional Neural Network (1D-DCNN) techniques. For age estimation using the extracted features, Genetic Algorithm and Random Forest Algorithm were modified, combined, and referred to as Modified Genetic-Random Forest Algorithm (MG-RF). The performance of the system was analyzed based on the calculated MSE, MAE, RMSE, and R^2 values during the implementation of the code.

Results: While MSE value was found to be 0,00027, MAE value was 0,0079, RMSE was 0,0888 and R^2 was 0,999.

Conclusion: It can be concluded that our study has demonstrated an effective performance in age determination given the acceptable difference of ± 1.00 year between estimated dental age and chronological age from birth to adolescence in forensic sciences. Therefore, we believe that the system employed in our study may have the potential to be used in the future within the scope of forensic sciences.

Keywords: age estimation, dental age estimation, forensic odontology, deep learning, deep-CNN

İÇİNDEKİLER

ÖZET	I
ABSTRACT	II
İÇİNDEKİLER	III
SİMGELER ve KISALTMALAR DİZİNİ	VII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ	X
1. GİRİŞ	1
2. GENEL BİLGİLER	3
2.1. Adli Bilimler ve Adli Diş Hekimliği	3
2.1.1. Adli Diş Hekimliğinde Tarihsel Bilgiler	4
2.1.2. Kronolojik Yaş ve Biyolojik Yaş	5
2.2. Diş Gelişimi ve Diş Sürmesi	5
2.2.1. Diş Gelişiminin Aşamaları	6
2.2.2. Diş Köklerinin Gelişimi	9
2.2.3 Diş Sürmesi	11
2.2.4. Oklüzyon Gelişimi	14
2.3. Dişlerin Yapısı ve Yaşla Gelişen Değişiklikler	16
2.3.1. Mine	16
2.3.2. Dentin	18
2.3.3 Sement	21
2.3.4. Pulpa	22
2.4. Çocuklarda ve Adölanlarda Dental Yaş Belirleme Metotları	23
2.4.1. Schour ve Massler Metodu	23
2.4.2. Gleiser ve Hunt Metodu	24
2.4.3. Nolla Metodu	24
2.4.4. Moorrees, Fanning ve Hunt Metodu	25
2.4.5. Anderson, Thomson ve Popovich Metodu	25
2.4.6. Mörnstaad, Staaf ve Welander Metodu	25
	III

2.4.7. Demirjian Metodu	26
2.4.8. Willems Metodu	27
2.4.9. Cameriere Metodu	28
2.5. Yetişkin Bireylerde Dişlerde Yaşa Bağlı Oluşan Değişikliklere Göre Uygulanan Yaş Tahmin Metotları	28
2.5.1. Gustafson Metodu	28
2.5.2. Lamendin Metodu	29
2.5.3. Atrizyon Metodu	29
2.5.4. Kök Transparanlığına Göre Metotlar	30
2.5.5. Sement Apozisyonuna Göre Metotlar	30
2.5.6. Aspartik Asit Rasemizasyonuna Göre Metotlar	31
2.5.7. Radyoaktif Karbon 14'e Göre Metotlar	31
2.5.8. Telomer Kısalmasına Göre Metotlar	31
2.5.9. Sekonder Dentin Birikimine Göre Metotlar	32
2.5.10. Diğer Metotlar	32
2.6. Yetişkin Bireylerde Radyograflar Üzerinden Gerçekleştirilen Yaş Tayini Metotları	33
2.6.1. Drusini Metodu	33
2.6.2. Cameriere Metodu	33
2.6.3. Kvaal Metodu	33
2.6.4. Diş ve Pulpa Hacmi Kullanılarak Geliştirilen Metotlar (Üç Boyutlu Ölçümler)	34
2.7. Dişlerden Yaş Tayini Yapılırken Kullanılan Radyograflar	35
2.7.1. Periapikal Radyograflar	35
2.7.2. Panoramik Radyograflar	35
2.7.3. Mikro-Bilgisayarlı Tomografi (Mikro-BT)	35
2.7.4. Konik Işınlı Bilgisayarlı Tomografi (KIBT)	36
2.8. Zeka ve Yapay Zeka	36
2.8.1. Yapay Zekanın Tarihsel Gelişimi	37
2.8.2. Güçlü Yapay Zeka, Zayıf Yapay Zeka Kavramları ve Düşünce Deneyleri	39
2.9. Yapay Zeka Algoritmaları	41
2.9.1. Uzman Sistemler	41
2.9.2. Bulanık Mantık	41
2.9.3. Genetik Algoritmalar	42

2.9.4. Yapay Sinir Ağları	42
2.9.5. Makine Öğrenmesi	46
2.10 Derin Öğrenme	48
2.10.1. Derin Konvolüsyonel Sinir Ağları	49
2.10.2. Derin Öğrenmenin Katmanları	50
2.10.3. Konvolüsyonel Sinir Ağlarının Eğitilmesi	53
2.11. Diş Hekimliğinde ve Ağız, Diş ve Çene Radyolojisi Alanında Yapay Zeka Uygulamaları	54
3. GEREÇ ve YÖNTEM	60
3.1. Hasta Seçimi ve Veri Kümesinin Oluşturulması	60
3.2. Çalışmanın Genel Akış Diyagramı	60
3.2.1. İki Boyutlu Derin Konvolüsyonel Yapay Sinir Ağı (2D-DCNN)	63
3.2.2. Tek Boyutlu Derin Konvolüsyonel Yapay Sinir Ağı (1D-DCNN)	66
3.2.3. Öznitelik Birleştirme	68
3.3. Modifiye Genetik-Rastgele Orman Algoritması (Modified Genetic-Random Forest, MG-RF)	68
3.3.1. Genetik Algoritma	68
3.3.2 Karar Ağaçları ve Rastgele Orman Algoritması	69
4. BULGULAR	76
4.1. Keşif Verisi Analizi	76
4.2. Performans Metrikleri	78
4.2.1. Standart Sapma	78
4.2.2. Ortalama Mutlak Hata	78
4.2.3. Ortalama Kare Hatası	79
4.2.4. Kök Ortalama Kare Hatası	79
4.2.4. Determinasyon Katsayısı	79
4.3. Performans Analizi	79
5. TARTIŞMA	81
5.1. Manuel Yaş Tahmin Metotları	82
5.1.1. Demirjian ve Willems metodunun etkinliğinin çeşitli dünya popülasyonları üzerinde değerlendirildiği çalışmalar	82
5.1.2. Demirjian ve Willems metodunun Türk popülasyonu üzerinde kullanımı	84

5.2. Yapay Zeka Algoritmalarına Dayalı Yaş Tahmin Çalışmaları	88
5.2.1 Makine Öğrenimine Dayalı Çalışmalar	90
5.2.2 Derin Öğrenmeye Dayalı Çalışmalar	95
5.2.3 Derin Öğrenme ve Makine Öğrenimine Dayalı Hibrit Çalışmalar	110
6. SONUÇ VE ÖNERİLER	112
KAYNAKLAR	114
EKLER	
Ek 1. ETİK KURUL ONAY FORMU	
Ek 2. ÖZGEÇMİŞ	

SİMGELER VE KISALTMALAR DİZİNİ

1D-DCNN: Tek Boyutlu Derin Konvolüsyonel Sinir Ağı

2D-DCNN: İki Boyutlu Derin Konvolüsyonel Sinir Ağı

ADAB: AdaBoost

AGM: Aktif Görünüş Modeli

AŞM: Aktif Şekil Modeli

b: Bias

BBC: Britanya Yayın Kuruluşu

BRR: Bayesian ridge regresyon

Ca₁₀(PO₄)₆(OH)₂: Hidroksi apatit

cGA: Kompakt Genetik Algoritma

Deep-CNN: Derin Konvolüsyonel Sinir Ağları

DNA: Deoksiribo nükleik asit

DT: Karar ağacı

GA: Genetik Algoritma

IBM: Uluslararası İş Makineleri

KIBT: Konik ışınlı bilgisayarlı tomografi

KNN: K-en yakın komşu

kVp: Peak kilovoltaj

LR: Doğrusal regresyon

mA: Miliamper

MAE: Ortalama Mutlak Hata

MG-RF: Modifiye Genetik-Rastgele Orman Algoritması

Mikro-BT: Mikro-bilgisayarlı tomografi

MLP: Çok katmanlı algılayıcı

mm: Milimetre

MSE: Ortalama Kare Hatası
nm: Nanometre
no: Numara
p: İstatistiksel anlamlılık
POLYREG: Polinom Regresyon
R²: Determinasyon Katsayısı
ReLU: Aktivasyon Katmanı
RF: Rastgele orman
SD: Standart Sapma
sn: Saniye
STACK: Yığınlama
SVM: Destek vektör makinesi
VOTE: Oylama
w: Sinaptik ağırlık
x: Giriş sinyali
µm: Mikrometre
φ: Aktivasyon fonksiyonu

ŞEKİLLER DİZİNİ

<u>Şekil No</u>	<u>Sayfa No</u>
Şekil 2.1. Yapay sinir ağı hücresi modeli	43
Şekil 2.2. Derin Öğrenme yapısı	49
Şekil 2.3. Drop out işlemi uygulanmamış ve uygulanmış bir sinir ağı modeli	52
Şekil 3.1. Çalışmamızın genel akış diyagramı	62
Şekil 3.2. 2D-DCNN'nin genel mimarisi	63
Şekil 3.3. 1D-DCNN'nin çalışma süreci	68
Şekil 3.4. Modifiye Genetik-Rastgele Orman algoritmasının genel iş akışı	71
Şekil 4.1. Veri kümesinden örnek panoramik radyograf görüntüleri	77
Şekil 4.2. Tahmin edilen değerler ve gerçek değerlerin karşılaştırmalı olarak analizini gösteren grafik	80

TABLULAR DİZİNİ

<u>Tablo No</u>	<u>Sayfa No</u>
Tablo 2.1. Süt dişlerinin sürme zamanları	13
Tablo 2.2. Daimi dişlerin sürme zamanları	13
Tablo 2.3. Nolla metoduna ait diş gelişim aşamaları	25
Tablo 2.4. Demirjian metoduna ait gelişim aşamaları	26
Tablo 3.1. 2D-DCNN'nin genel algoritması	66
Tablo 3.2. Öznitelik birleştirme	68
Tablo 3.3. Genetik algoritma	72
Tablo 3.4. Uygunluk hesaplaması	73
Tablo 3.5. Genetik algorithmadan çıkarılan en iyi parametreler	73
Tablo 3.6. Optimize edilmiş RF	74
Tablo 3.7. RF için hiperparametreler	74
Tablo 4.1. Veri setini oluşturan hasta kayıtlarına ait örnekler	77
Tablo 4.2. Toplam hasta sayısı ve yaş ortalaması	78
Tablo 4.3. Çalışmamızda kullanılan sistemin değerlendirilen performans metriklerine göre bulguları	80
Tablo 5.1. Literatürde yapay zeka algoritmaları kullanılarak gerçekleştirilmiş çalışmalar	89
Tablo 5.2. Galibourg ve arkadaşlarının çalışmasına ait bulgular ve çalışmamızın bulgularıyla kıyaslaması	91
Tablo 5.3. Tao ve arkadaşlarının çalışmasına ait bulgular ve çalışmamızın bulgularıyla kıyaslaması	93
Tablo 5.4. Shen ve arkadaşlarının çalışmasına ait bulgular ve çalışmamızın bulgularıyla kıyaslaması	94
Tablo 5.5. Kim ve arkadaşlarının çalışmasında kullanılan sistemin odaklandığı bölgeler	99
Tablo 5.6. Ćular ve arkadaşlarının çalışmasına ait bulgular ve çalışmamızın bulgularıyla kıyaslaması	101
Tablo 5.7. Milošević ve arkadaşlarının çalışmasına ait bulgular	109

1.GİRİŞ

Bireylerin ruhsal ve fiziksel bakımdan zarara uğradığı durumlarda, adaletin sağlanabilmesi için, adli açıdan karar verecek görevlilerin, hekimlerin tanısalları yardımına başvurması evrensel bir görev olmalıdır. Bireylerin kimliklendirilmesi adli bilimlerin önemli bir konusunu oluşturmaktadır. Son yıllarda büyük bir artış yaşanan kitlesel felaketler, şiddet olayları, büyük yangınlar, uçak kazaları gibi durumlarda bireylerin çeneleri ve dişleri bozunmaya diğer dokulardan daha dirençli olduğu için kimliklendirmede önemli kriterlerden biri olarak karşımıza çıkmaktadır.¹

Bireylerin hukuki ve cezai ehliyetlerinin olup olmadığının tespiti, askere ve işe alınma durumu, bireyin işlediği veya maruz kaldığı fiillerin sonuçlarını ve anlamlarını algılayacak yaşta olup olmadığını tespit etme gibi durumlarda bireyin yaşının bilinmesi gerekmektedir.¹ Adli bilimlerde, yaş tahmini alanında en çok kullanılan vücut kısmı dişlerdir. Diş dokusu, bileşimi nedeniyle iskeletin en dayanıklı parçasıdır. Çok yüksek sıcaklık gibi aşırı koşullara dayanıklıdır. Ayrıca kemiklerin bozunuma uğramasından sonra bile uzun süre boyunca stabil bir biçimde korunabilmektedir. Dişlerin gelişimi hem genetik hem de çevresel faktörler tarafından etkilenen bir süreçtir. Ancak diş mineralizasyonu bu faktörlerden, kemik mineralizasyonu kıyasla daha az etkilenmektedir. Bu nedenle diş dokularının, kronolojik yaşın göstergeleri bakımından kemik dokulara kıyasla daha çok bilgi içerdiği literatürde bildirilmiştir.²

Literatürde yaş tahmini yapmak amacıyla, dişlerde meydana gelen gelişim ve değişimlerden faydalanılarak radyografik, histolojik ve biyokimyasal yöntemlerle geliştirilmiş metotlar bildirilmiştir.^{3,4} Ancak büyüme ve gelişim hızı her toplum için kendine özgü bir nitelikte seyretmesi nedeniyle evrensel olarak geçerli tek bir metot bulunmamaktadır ve yaş tahmin metotlarının farklı topluluklarda uygulanması ve güvenilirliklerinin araştırılması gerekmektedir.² Mevcut yaş tahmini metotları, iyi performans göstermesine, yaygın olarak kullanılmasına rağmen fazla çaba ve zaman gerektiren manuel ölçümlere ve insan tahminlerinde gözlemci öznelliğine dayanmaktadır. Bu durum, özellikle adli tıp uzmanlarının iş yükünün makul miktarları çok aştığı toplu afetlerde öznel hataların sonuçları etkileyebilmesine yol açmaktadır.^{5,6}

Yapay zeka, insan veya diğer doğal sistemlerin yapma becerisine sahip oldukları yetileri taklit edebilen makine ve bilgisayar sistemleridir. Karmaşık

problemlerde insanların düşünme stillerini taklit ederek, insanlara benzer çözümler sunmaya yarayan teknolojilerdir. Yapay zekanın alt dalları; uzman sistemler, bulanık mantık, genetik algoritmalar, yapay sinir ağları, makine öğrenmesi ve derin öğrenme olarak sıralanabilmektedir.^{7,8}

Son yıllarda diş hekimliği pratiğinde, panoramik radyografları içeren görevlerin otomatikleştirilmesi amacıyla yapay zeka algoritmalarına dayanan çalışmalar gerçekleştirilmiştir.⁶ Bu çalışmalara dişlerin saptanması ve sınıflandırılması, yetersiz kalitedeki panoramik radyografların otomatik biçimde yeniden rekonstrüksiyonu, osteoporoz teşhisi, odontojenik kist ve tümörlerin teşhisi hedefiyle gerçekleştirilmiş çalışmalar örnek verilebilir.⁹

Adli bilimlere ait veriler, çözümü kolaylıkla gerçekleştirilemeyecek büyüklükte veri setlerine, rasyonel analiz gereksinimi duyan karmaşık ilişkilere sahiptir. Bu nedenle yapay zeka uygulamaları, adli görevliler arasındaki iletişim açığı sebebiyle ortaya çıkabilecek adaletin yanlış işleyişi problemlerinin çözümüne destek sağlayan teknolojiler olarak karşımıza çıkmaktadır.¹⁰ Literatürdeki çalışmalarda, yapay zeka algoritmalarının, eğitilmiş adli bilim çalışanlarıyla en az eşdeğer doğruluk ve hassasiyet gösterdiği bildirilmiştir.¹¹

Bu tez çalışmasında, yapay zeka algoritmaları kullanılarak bireylerin yaş tahmini yapılması amacıyla otomatik bir sistem kullanılmıştır. Bu amaçla veri setimizi oluşturan bireylerin panoramik radyograflarından ve hasta kayıtlarından oluşan verilerden 2D-DCNN ve 1D-DCNN teknikleri kullanılarak öznitelik çıkarımı gerçekleştirilmiştir. Öznitelik bilgileri kullanılarak yaş tahmini gerçekleştirmek için ise GA ve RF algoritması modifiye edilerek birleştirilmiş ve MG-RF olarak tanımlanmıştır.

2. GENEL BİLGİLER

2.1 Adli Bilimler ve Adli Diş Hekimliği

Bireylerin ruhsal ve fiziksel bakımdan zarar gördüğü olgularda, adaletin yerine getirilebilmesi için adli karar mercileri, tarih boyunca hekimlerin tanısai görüşlerine başvurmuşlardır.¹ Bireysel ve toplumsal felaket mağdurları, bireysel ölüm vakaları ve toplu mezarlar gibi günümüzde sıklıkla karşılaşılan durumlar, teşhis edilemeyen cesetlerin kimliklendirilmesi, adli tıbbın en önemli görevlerinden biri haline gelmiştir.¹²

Adli diş hekimliği; adli olgularda dişlere ait bulguların adalet yararına sunulması, uygun bir biçimde incelenmesiyle kimlik ve delil tespiti, yaş tahmini, cinsiyet belirleme gibi diş hekimlerinin medikolegal sorumluluklarını yerine getiren bir diş hekimliği dalıdır.¹ Adli bilimlerde kimlik tayini kapsamında, dişler, parmak izleri, el ayası izleri, ayak izleri, DNA örnekleri; pelvis, vertebralar, kraniyal yapılar ve kemik trabeküllerinin radyografik incelemeleri gibi metotlar kullanılmaktadır.¹³ Yaş, cinsiyet, boy, dişler, göz ve saç rengi, parmak izi bir bireyin tıbbi kimliğini oluşturan en önemli fiziksel özellikler olarak bildirilmiştir.¹⁴

Adli bilimlerde, bireyin yaşının belirlenmesi oldukça önemli bir konudur. Kimlik bilgileri güvenilir olmayan bireylerde hukuki ve cezai sorumluluğun olup olmadığı, bireylerin okula ve işe kabulü, askere alınma durumu, küçük çocuklar için maruz kalınan fiillere karşı savunma durumunun bulunup bulunmadığı ve bireyin gerçekleştirdiği fiillerin sonuç ve anlamlarını algılayabilecek yaşta olup olmadığının tespit edilmesi gibi durumlarda bireyin yaşının bilinmesi gerekmektedir.¹ Yaş tespiti genellikle kimliklendirme amacıyla kullanılmasına rağmen ülkemizde özellikle kırsal kesimlerde, doğum ve nüfus kayıtlarının zamanında yapılmaması nedeniyle kimliği bilinen bireylerin gerçek yaşlarının tespiti için de sıkça kullanılmaktadır.¹⁵

Güvenilir yaş verilerinin bulunmadığı durumlarda kemik yaşı ve diş yaşı, yaş tespitinde kullanılabilir. İskelet radyolojisi yaş tespitinde en sık incelenen veri olsa da doku ve kemiklerin bozunuma uğramasından sonra uzun süre korunması ve diğer dokulara kıyasla daha stabil bir doku olmasından dolayı dişlerin radyografik olarak incelenmesi diğer metotlara göre daha doğru sonuçlar vermektedir.¹⁶ Ayrıca diş

dokularının gelişimi, vücudun diğer sistemlerinin gelişimiyle karşılaştırıldığında genetik ve çevresel faktörlerden daha az etkilenmektedir. Bu nedenle yaş tahmini yapılması için dişler elverişli bir doku olarak karşımıza çıkmaktadır.¹⁷

2.1.1 Adli Diş Hekimliğinde Tarihsel Bilgiler

Adli diş hekimliğinde, dişlerin değerlendirilmesiyle gerçekleştirilen kimliklendirme sıklıkla kullanılan bir uygulamadır. Diş izlerinin varlığı ve her diş izinin bireye özgü olması ise tarih öncesi insanlar tarafından dahi bilinen bir durum olarak karşımıza çıkmaktadır. Dolayısıyla ilkel biçimlerde bile olsa, kimliği bilinmeyen insan kalıntılarının kimlik tespitinde dişlerin kullanılması tarih öncesi çağlara kadar uzanmaktadır.¹

Adli diş hekimliği kayıtlarına geçen ilk belge, Romalı yazar Dion Cassius'un Roma Tarihi adlı kitabında geçen Agrippina ve Lollia Paulina vakasıdır. Aktarılan bilgilere göre bu vakada yumuşak dokuları kısmen bozunmaya uğramış maktul Lollia Paulina'nın kimliği Agrippina tarafından dişlerine bakılarak tespit edilmiştir.¹ Dişleri kullanarak kimliklendirmenin yasal kullanımıyla ilgili en önemli örnek 1775 yılında Dr. Paul Revere'nin, bir koloni liderinin kimlik teşhisini, maktulün diş muayenesini gerçekleştirilmesi sonucu daha önce yaptığı gümüş köprü protezi ve maktulün diş morfolojisini tanınması ile kayıtlara geçmiştir. Böylece Dr. Paul Revere, diş hekimliği tarihinde, diş hekimi sıfatıyla dişlerden kimliklendirme yapan ilk kişi olmuştur.¹³

Dişlerin, bireylerin kimliklendirilmesinde kullanılabilecek bilimsel bir yöntem olması ise 1887 yılında Paris'te gerçekleşen Odontoloji Cemiyeti toplantısında kabul edilmiştir.¹ Ardından 1898 yılında, adli odontolojinin babası kabul edilen Dr. Oscar Amoedo tarafından ilk adli odontoloji kitabı yayınlanmıştır.¹³

Diş dokularının yaş tespitinde kullanılmasının gündeme gelişi 19. yüzyıla uzanmaktadır. İngiltere yasalarına göre yedi yaş altındaki çocuklar cezai sorumluluk sahibi değildir. Ayrıca 19. yüzyılda doğum kayıtlarının düzenli bir biçimde tutulmaması nedeniyle bireyin cezai sorumluluğunun tespiti için yaş tahminine ihtiyaç duyulmuştur. Bu konuda medikolegal uzman Thomson tarafından, “Eğer üçüncü molar sürmemişse suçlunun yedi yaşını geçmediği konusunda herhangi bir şüphe yoktur.” kuralı öne sürülmüştür. Thomson'un öne sürdüğü bu kuralda üçüncü molar

olarak adlandırdığı diş, daimi birinci molar dişlerdir. Süt ikinci molar dişlerin distalinden sürmesi nedeniyle bu dişler üçüncü molar diş olarak ifade edilmiştir.¹⁸

Adli bilimlerin kapsamında radyografların kullanımı ise ilk defa Prof. Arthur Schuster tarafından, x-ışınlarının keşfinden yaklaşık bir sene sonra 1896 yılında, maktullerin kafatası içindeki mermilerin tespiti için kullanılmıştır.¹⁹

Ülkemizde adli diş hekimliği adına, yakın zamana değin ciddi çalışmalar yürütülmemiştir. Adli diş hekimliğinin önemi, bu konudaki deneyim ve çalışmaların artmasıyla gündeme gelmiştir. 1992 yılından itibaren ise, Adli Tıp Kurumu'na gelen dosyalardan diş hekimlerinin alanına girenlerin değerlendirilmesinde, eğitim almış diş hekimlerinin aktif olarak görevlendirilmesine başlanmıştır.¹

2.1.2 Kronolojik Yaş ve Biyolojik Yaş

Kronolojik yaş, bir bireyin doğduğu andan itibaren geçen zaman olarak tanımlanmaktadır. Adli bilimler kronolojik yaşı bireylerin doğum ve ölüm tarihleri arasında geçen zaman olarak ele almaktadır. Dolayısıyla kronolojik yaşın bilinmesi için, bireyin doğum ve ölüm tarihlerinin net bir biçimde bilinmesine ihtiyaç duyulmaktadır. Ancak bu bilgilere sahip olunamıyorsa bireylerin biyolojik gelişimleri incelenerek yaş tahmini gerçekleştirilebilmektedir. Biyolojik yaş, kronolojik yaşın aksine doğumdan itibaren geçen yıllarla değil bireyin boy, kilo, kıl, cilt, göz, diş, kemik, ikincil cinsiyet özellikleri gibi farklı sistemlerin fiziksel gelişim aşamaları veya bu sistemlerdeki yaşlanma ile görülen değişikliklerin değerlendirilmesiyle belirlenmektedir. Biyolojik yaş ile kronolojik yaş arasında yakın bir ilişki vardır. Ancak biyolojik yaş, bireyin yaşam koşullarına bağlı olarak kronolojik yaştan sapma gösterebilir. Irksal farklılıklar, sosyoekonomik düzey, yaşam tarzı gibi bireysel faktörler, sistemik hastalıklar bireylerin gelişimleri üzerinde etkisi olan durumlardır ve biyolojik yaşta varyasyonlara yol açmaktadır. Yaş tahmini yapılırken meydana gelebilecek olası hatalar bireylerin bu varyasyonları göstermelerine bağlı olarak gerçekleşebilmektedir.^{17,20-23}

2.2 Diş Gelişimi ve Diş Sürmesi

Dişler, yalnızca omurgalı canlılarda bulunmaktadır. Canlılardaki epitelyal-mezenşimal doku etkileşiminin klasik bir örneğini teşkil etmektedir. Dişler, oral

ektoderm hücreleri ile bu hücrelerin altında konumlanmış olan mezenşimal hücreler arasındaki etkileşimin sonucunda oluşmaktadır. İnsanlar, difiyodont olarak da tanımlanan, süt diş dizisine ait 20 diş ve daimi diş dizisine ait 32 diş içermekte olan iki diş dizisine sahip bir türdür. Gelişmekte olan her bir diş, anatomik olarak farklı bir birim olarak büyümektedir, ancak temel gelişim süreci tüm dişlerde benzer bir şekilde gerçekleşmektedir.^{24,25}

Dişlerin gelişimi ve dişlerin şekillerinin regülasyonu, temelde mezenşim dokusunda eksprese edilen homeobox geninin alt grubu olan HOX genleri ile düzenlenmektedir. Bu regülasyonda ayrıca transkripsiyon faktörleri, WNT gelişim sinyalleri, kemik morfogenetik proteinler, fibroblast büyüme faktörleri, sonic hedgehog geni, MSX-1 ve MSX-2 genleri rol oynamaktadır.²⁴

İntrauterin gelişimin altıncı haftasında, homeobox geni MSX-1'in lokalize olduğu alanlarda oral ektoderm hücrelerinin çoğalması ile alt ve üst çeneler boyunca C şekilli bir lamina oluşturması, diş gelişimine dair görülen ilk morfolojik işarettir. Diş gelişiminin erken dönemlerinde diş germlerinin oluşması ve boyutsal olarak gelişmesi izlenmektedir. İlerleyen dönemlerde dişlerin sert dokularını oluşturacak hücrelerin bu dönemde ayrımı yapılabilmektedir. Diş germlerinin oluşumunun ardından kronların formlarının belirginleşmesi ve mineralizasyon süreci gelmektedir. Kronların şekillenip mineralize olmasını takiben kök formasyonu ve kalsifikasyonu meydana gelmektedir. Diş köklerinin kalsifikasyonundan sonra sement, periodontal ligament ve alveolar kemikten oluşan diş destek dokularının gelişimi başlamaktadır. Bu aşamaların ardından gelişimi tamamlanmış diş ağız ortamına sürmektedir. Ancak kök gelişimi ve sementogenez süreçleri, diş fonksiyonel bir yapı kazanana ve diş destek yapıları tam olarak gelişene kadar devam etmektedir.²⁵

2.2.1 Diş Gelişiminin Aşamaları

Diş gelişimi devamlılık gösteren bir süreç olmasına rağmen, ardışık olarak tomurcuk, takke ve çan aşamaları olarak birbirinden kolaylıkla ayrımı sağlanan bir dizi aşama ile karakterize edilmektedir. Her aşama, gelişmekte olan dişin ektodermden türemiş mine organının o esnadaki şekline göre tanımlanmaktadır.²⁵

Birinci aşama, tomurcuk aşaması olarak isimlendirilir. Tomurcuk aşaması, proliferen olan mezenşim hücreleriyle çevrili ektoderm hücrelerinin, lokalize, yuvarlak

bir büyümesidir. Epitel tomurcuğu genişleyip büyüdükçe, iç bükey bir yüzey kazanır ve bu görünüme takke aşaması adı verilir. Bu ektodermal yapı daha sonra, mine organını oluşturmak üzere farklılaşır ancak dental laminaya bağlı kalır. Ardından ektomezenşim, mineralize bir dokuyla çevrelenir ve ileride diş pulpası haline gelecek olan diş papillası oluşur. Mine organı ve dental papillayı çevreleyen dokuya diş folikülü adı verilir. Gelişimin ilerleyen evrelerinde destek dokulardan olan periodontal ligament ve sement bu diş folikülünden gelişmektedir.²⁵

Mine organı ve dental papillanın daha da büyümesinin ardından gelişmekte olan diş, aynı zamanda çan aşaması adı da verilen histodiferensiyasyon ve morfodiferansiyasyon aşamasına ulaşır. Bu aşamada, mine organının hücreleri, mine organını dıştan kaplayan dış mine epitel hücrelerine ve diş kronunun minesini oluşturmak üzere ameloblastlar haline gelecek iç mine epitel hücrelerine dönüşürler. İç mine epitel hücreleri, oluşturmak üzere geliştikleri kronun şeklini almışlardır. Dış mine epitel hücrelerinin temel görevi ise ameloblast hücrelerinin beslenmesini sağlamak üzere görev alan kılcal damar ağının düzenlenmesidir. İç mine epiteli ve dış mine epitelini oluşturan hücre tabakalarının arasında birbirlerine stoplazmik uzantılarla bağlı şekilleri yıldız benzeyen stellate retikulum hücreleri bulunmaktadır. Stellate retikulum hücreleri, hücre dışı matrikste yer alan ve gelişimine devam eden kron için gerekli yerin korunmasını sağlayan hidrofilik glikozaminoglikanları içermektedir. Ayrıca ameloblastlar için gerekli besin maddeleri süzülme yoluyla ameloblast hücreleri içine stellate retikulum aracılığıyla temin edilmektedir.²⁵

Çan aşamasında, dental papillanın çevresindeki nöral krest ve ektomezenşim hücreleri odontoblastlara farklılaşmaktadır. Odontoblastlar, boyca uzayıp, silindirik hale geldikten ve kutuplaştıktan sonra, predentin olarak adlandırılan %90'ı tip 1 kolajenden ve %10'u kolajen olmayan proteinlerden oluşan bir hücre dışı matriks sentezlemektedirler. Bu hücre dışı matriks yirmi dört saat sonra kalsifiye olup dentine dönüşmektedir. Birkaç tabaka dentin oluşumundan sonra, farklılaşmış olan ameloblastlar mine matriksi biriktirmeye başlamaktadır. Diş gelişimde dentinogenezis süreci, her zaman amelogenezisten önce gelmektedir. Mine organının farklılaşmasından sonra dental lamina otolize uğrayarak dejenere olmaya başlamaktadır. Dental lamina, arkların anterior kesiminde kısa süre içinde kaybolmasına rağmen posterior kesiminde uzun yıllar aktif olarak kalmaktadır.²⁵

Dentinogenez

Odontoblast hücreleri uzadıkça ve fonksiyon gösterdikçe, çekirdekleri hücre bazalinde konumlanır. Organelleri hücre stoplazmasında daha belirgin hal alır ve protein üreten hücrelerin doğasını yansıtacak bir görünüm kazanırlar. Dentinogenez süreci, odontoblast hücresinin proksimal ucunda mine-dentin birleşimine bitişik olarak gelişmektedir. Odontoblast hücreleri yavaş yavaş pulpaya doğru hareket etmektedir ve odontoblast uzantısı olarak bilinen bir hücre prosesini oluşturmaktadır. Odontoblast hücresi, osteoblast hücresine benzer bir biçimde dentin matriksi oluşumunda aktif hale gelir ve mine-dentin birleşimi boyunca dentin yapımında tabakalı artışlar görülür.²⁵

Dentin matriksi, ilk oluştuğu zaman tip 1 kolajen liflerinden oluşmuş bir ağ yapısı göstermektedir. Bu kolajen ağ yapısı yirmi dört saat içinde kalsifiye olmaktadır. Bu ağ yapısına, kalsifikasyonun gerçekleşmesinden önce preentin, kalsifikasyonun gerçekleşmesinden sonra ise dentin adı verilmektedir. Dental papilla ise, gerçekleşen bu kalsifikasyonun ardından, dentin dokusuyla çevrenmeye başlaması nedeniyle artık pulpa olarak isimlendirilmektedir.²⁵

Dentinogenez, iki safhada gerçekleşmektedir. İlki kolajen matriks oluşumu, ikincisi ise matriks içinde kalsiyum fosfat kristallerinin (kalsiyum hidroksiapatit) birikmesi safhasıdır. Başlangıç kalsifikasyonu, kolajen ağı içinde yüzeysel olarak küçük kristaller halinde gerçekleşmektedir. Kolajen matriksin kalsifikasyonu tamamlanana kadar bu kristaller büyümekte, genişlemekte daha sonra ise birleşmektedirler. Pulpaya komşu olan dentin matriks bandı kalsifiye değildir. Bu nedenle matriks oluşumu ile mineralizasyon süreci birbirleriyle yakın ilişkilidir. Mineralizasyon aşaması, oluşan dentindeki mineral yoğunluğunun artışıyla devam etmektedir. Pulpa sınırında günlük olarak yeni preentin oluşumuyla birlikte, önceki gün sentezlenen preentin kalsifiye olur ve dentin halini alır. Bu tabakalı birikim modeli, diğer kemik dokularında olduğu gibi mine ve dentin dokularının oluşumunda da görülen günlük ritmin bir göstergesidir.²⁵

Amelogenez

Ameloblast hücreleri tarafından mine dokusunun sentezine, mine-dentin birleşiminde mineralize dentin birikimi birkaç mikrometreye ulaştığında

başlanmaktadır. Mine sentezi, salgılanması ve takip eden mineralizasyon, yapısal proteinlerden amelogenin, ameloblastin ve minelini, proteinazlardan ise kallikrein-4 ve enamelinini içeren bir süreçtir. Gelişimin çan aşamasında, iç mine epiteli hücreleri boyca uzamakta ve aktif salgı ameloblastlarını oluşturmak üzere farklılaşmaktadırlar. Ameloblastlar farklılaşırken morfogenez, organizasyon ve farklılaşma, salgılama, olgunlaşma ve koruma olmak üzere beş fonksiyonel safhadan geçmektedir.²⁵

Mine matriksi oluşturulduktan sonra, ameloblastların hücre zarına bağlı veziküller halinde paketlenmektedir. Bu veziküller ameloblast hücresinin apikal ucuna göç etmekte ve içerdiği mine matriksi ekzositoz aracılığıyla salgılanmaktadır. Mine matriksi, ilk başta mine-dentin birleşimi boyunca birikmektedir. Dentin dokusunun yüzeyinde biriken bu ilk mine dokusu, mine-dentin birleşimini oluşturmaktadır. Amelogenезin başlangıcında, tüberkül tepeleri hizasındaki birkaç ameloblast hücresi fonksiyon görmeye başlamaktadır. Amelogenез süreci ilerledikçe daha fazla ameloblast hücresi aktifleşmektedir ve mine matriksindeki artış daha da belirgin bir hal almaktadır.²⁵

Ameloblastlar, iç mine epitelinden gelişmektedirler. Dolayısıyla, gelişmekte olan kronun görünüşünün planını iç mine epiteli oluşturmaktadır. Her bir tüberkül tepesinde, mine düğümü olarak adlandırılan ve kronun gelişimini koordine eden hücre yoğunlaşması meydana gelmektedir. Tabakalı birikim modeli ile birbirinden ayrı tüberküllerin gelişimi diş ağız ortamına sürene kadar devam etmektedir. Tüberküller daha sonra kronun interkusal bölgesinde birleşmektedir. Dolayısıyla gelişmekte olan bir diştен alınan radyograflarda, gelişimin başlangıç aşamalarında tüberküller ayrı ayrı görünümde izlenmektedir.²⁵

2.2.2 Diş Köklerinin Gelişimi

Diş kronu geliştikçe hücre proliferasyonu, iç ve dış mine epitel hücrelerinin kök kınını oluşturmak üzere birleştiği mine organının servikal bölgesinde ve tabanında devam etmektedir. Kron oluşumu tamamlandığında, mine organının servikal bölgesindeki hücreler, epitelyal kök kını veya Hertwig'in epitelyal kök kını olarak da adlandırılan çift tabakalı bir hücre yapısı oluşturarak büyümeye devam etmektedir. Kök kınının iç kısmındaki hücre tabakası, krondaki iç mine epitelinden ve ameloblastlardan oluşur. Bu hücrelerden mine dokusu sentezlenir. Bu hücreler, diş

papillasını odontoblastları farklılaştırmak ve dentini oluşturmak üzere indüklemektedir. Kök kını, mine birikintilerinin bittiği noktada başlar. Kök kınının uzamaya devam etmesiyle diş kökünün oluşmasına zemin hazırlanmaktadır. Köklerin uzunluğu, eğriliği, kalınlığı ve sayısı, iç kök kını hücrelerine bağlı olarak belirlenmektedir. Kökte dentin oluşumu devam ettikçe iç kök kını hücreleri, dentin tübüllerinin açık uçlarını örten ve kök yüzeyini kapatan ince bir hücresiz sement tabakası olan ara sement birikimi gerçekleşir. Ara sement dokusu, epitel kökenli keratin benzeri bir proteinden gelişen bir yapıdır. Daha sonra kök kını hücreleri küçük kümeler halinde dağılır ve epitel uzantıları olarak kök yüzeyinden uzaklaşır. Folikül ve diş pulpası hücreleri, pulpa tarafında kök dentinini oluşturmak üzere odontoblastlara farklılaşmaya indüklenir. Bu hücreler folikül tarafında ise alveolar kemiği oluşturmak üzere osteoblastlara, periodontal ligamenti oluşturmak üzere fibroblastlara ve sement dokusunu oluşturmak üzere sementoblastlara farklılaşmaya indüklenir. Ardından kök kını parçalanır. Kök kını, kök ucuna gelmeden önce parçalanır ve ardından yeniden şekillenirse, kökte aksesuar veya lateral kanallar oluşabilmektedir. Kök kınının parçalanmayıp dentine bağlı kaldığı durumlarda ise mine incileri oluşabilmektedir.²⁵

Odontoblastlar pulpa sınırı boyunca farklılaştıkça kök dentinogenez süreci ilerlemekte ve dişin kökü boyca uzamaktadır. Dentin oluşumu krandan köke doğru devam etmektedir. Kök dentininin kalınlığı, krandan köke doğru, apikal epitel diyaframı olarak adlandırılan bölgeye gelene kadar incelmektedir. Epitel diyaframı bölgesinde ise bu bölgeye bitişik pulpa dokusunda bir hücresel proliferasyon izlenmektedir ve bu bölge pulpa proliferasyon bölgesi olarak adlandırılmaktadır. Pulpa proliferasyon bölgesinin kök uzaması için gerekli olan yeni hücreleri ürettiğine inanılmaktadır. Kökteki dentinogenez süreci, uygun kök uzunluğuna ulaşılan kadar devam etmektedir. Dentin dokusu dişin kök ucunda apikal açıklık, yaklaşık 1 ila 3 mm ile sınırlanana kadar kalınlaşmaktadır. Bu apikal açıklık mesafesi, pulpa ve periodonsiyum arasında nöral ve vasküler iletişime izin vermek için yeterli bir mesafedir. Kron oluşumu tamamlandığında kök uzunluğundaki artışla birlikte diş, kökün daha da uzaması için alan sağlayan sürme hareketlerine başlamaktadır. Diş sürmesi meydana geldikçe kök de aynı oranda uzamaktadır.²⁵

2.2.3 Diş Sürmesi

Bir dişin alveol kemik içerisinde oluşup gelişim gösterdiği bölgeden ağız içinde fonksiyonel pozisyona gelmesine kadar gösterdiği hareketlerin tümü diş sürmesi olarak tanımlanmaktadır.²⁶ Diş sürmesi hayat boyu devamlılık gösteren dinamik bir süreçtir. Bu devamlılık ağız içerisinde karşıtı olmayan dişlerde belirgin olarak gözlenebilmektedir.²⁷ Bireyin büyüme ve gelişimi tamamlanincaya kadar çenelerin ve dişleri taşıyan alveolar segmentin sürekli büyümesine bağlı olarak dişler, vertikal, transversal ve sagittal yönde hareketlerine devam etmektedirler. Ancak büyüme ve gelişim tamamlandıktan sonra oldukça yavaş olmakla birlikte alveolar kemikte de bir büyüme bildirilmiştir.²⁸ Alveol kemikteki büyümenin temel kaynağı ise dişlerin gelişimi ve sürmeleridir.²⁹

Diş sürmesi; preeruptif faz, prefonksiyonel faz ve fonksiyonel faz olmak üzere üç farklı fazda ele alınır. Preeruptif faz, diş kökünün oluşumuyla indüklenen ve dişin kemik içerisinde ağız ortamına doğru hareket etmeye başladığı dönemdir. Prefonksiyonel faz, sürmekte olan dişin, diş eti içerisinde ağız ortamına çıkmasıyla başlayan dönemdir. Diş kökü uzunluğu bu dönemde, dişin ağız ortamında görülmesi esnasında, final uzunluğunun yaklaşık yarısı ile üçte ikisi kadardır. Dişin sürdükten sonra antagonistyle temas etmesi ile birlikte diş fonksiyonel fazda olduğu kabul edilir.³⁰

Sürme Kuvveti ve Kaynağı

Sürme hareketi genellikle dişlerin uzun aksı boyunca gerçekleşmektedir. Ancak diğer düzlemlerde de sürme hareketi görülür.²⁷ Literatürde sürme mekanizmasını açıklama doğrultusunda birçok kuram ortaya atılmıştır. Bu kuramlar içerisinde en çok kabul gören kuramlar şunlardır:

Kök büyümesi kuramı: Bu kuramda diş sürmesi esnasında belirgin olarak gerçekleşen kök gelişimi ve uzaması nedeniyle kök büyümesinin, diş sürmesini harekete geçiren mekanizma olduğu düşünülmüştür. Ancak, tip 1 dentin displazisinde olduğu gibi veya radyasyona maruz kalmış bireylerde görülen kök formasyonundaki belirgin bozukluklara rağmen, kökü bulunmayan dişler de ağız ortamına sürmektedir. Bu durumdan hareketle kök büyümesinin diş sürmesi için gerekli olmadığı, yalnızca

diş sürmesini hızlandırabilecek bir faktör olabileceği öne sürülmüştür. Ayrıca kök gelişimi tamamlanmış gömülü dişlerin de var olması, kök büyümesinin diş sürmesinin temelini oluşturamayacağını başka bir göstergesidir.^{27,31-33}

Alveolar kemik şekillenmesi kuramı: Bu kuramda gelişmekte olan dişin folikülünün, kemik rezopsiyon ve apozisyonu ile birlikte diş sürmesini de kontrol eden mekanizma olduğu düşünülmektedir.³⁴ Dişin sürme yolu boyunca alveolar kemik şekillenmesinin eksik olduğu durumlarda diş ağız ortamına sürememektedir. Ancak literatürde kemik şekillenmesinin diş sürmesinde tek başına etkili faktör olmadığı bildirilmiştir. Osteopetroz ve kleidokranial displazi olgularında görülen diş sürmesi bu duruma örnek olarak gösterilebilir.³³

Doku sıvısı ve kan basıncı kuramı: Diş sürmesi esnasında sürmekte olan dişin kök ucundaki ve kron kısmındaki doku sıvısı basıncında bir fark görülmektedir. Bu kuramda, sürmekte olan dişin kök ucundaki basıncın, kron kısmındaki basınçtan fazla olmasının sürme için gerekli kuvveti oluşturduğu düşünülmektedir. Doku basıncının farmakolojik olarak değiştirilmesiyle tavşanlardaki diş sürmesinde belirgin bir değişiklik görülmesi, bu kuramı destekler niteliktedir.²⁷

Periodontal membran şekillenmesi kuramı: Bu kuramda diş sürmesi için periodontal ligamentin temel faktör olduğu düşünülmektedir. Ancak osteopetroz olgularında periodontal membran bulunmasına rağmen dişlerin sürememesi veya tip 1 dentin displazisinde olduğu gibi kökü bulunmayan dolayısıyla periodontal membrandan yoksun dişlerin sürmesi, diş sürmesinde periodontal membranın tek başına etkili olmadığını destekler niteliktedir.³³

Polarize folikül teorisi: Bu kuram güncel literatürde diş sürmesinin başlangıcını en iyi şekilde açıklayan kuram olarak öne sürülmektedir. Bu kurama göre gelişmekte olan diş folikülün apikal kısmında gerçekleşen selektif alveol kemik büyümesi ile kök oluşumu indüklenmektedir. Kök oluşumu başladığında ise diş folikülünün kron kısmı koronal alveol kemik rezorpsiyon aktivitesini indüklemektedir. Alveolar kemikteki bu koordineli yapım ve yıkım aktivitesi sonucunda diş sürmesi gerçekleşmektedir.²⁸

Diş Sürmesini Etkileyen Faktörler

Süt ve daimi dişlerin sürmesi geniş bir yaş aralığı içerisinde tamamlanmaktadır. Dolayısıyla bu süreç pek çok faktörden etkilenebilmektedir. Bu faktörler yerel ve genel faktörler olarak ikiye ayrılmaktadır. Sürmeyi etkileyen yerel faktörler; yer darlığı, süpernumerer dişler, mezyodensler, ankiloze dişler, travma, malpozisyonlar, odontomalar olarak sıralanabilir.²⁸ Genel faktörler ise bireyin genetik yapısı, sahip olunan genetik sendromlar, cinsiyet, sosyoekonomik faktörler, bireyin beslenmesi, hormonal faktörler ve sistemik hastalıklardır.³⁵

Süt dişlerinin sürme zamanları sırası Tablo 2.1'de, daimi dişlerin sürme zamanları ve sırası Tablo 2.2'de verilmiştir.²⁹

Tablo 2.1 Süt dişlerinin sürme zamanları

Yaş	Süren Diş	
1 Yaş	7. Ay	I-I
	10. Ay	I+I
	12. Ay	II+II
2 Yaş	13. Ay	II-II
	16. Ay	IV±IV
	20. Ay	III±III
3 Yaş	30. Ay	V±V

Tablo 2.2 Daimi dişlerin sürme zamanları

Yaş	Süren Diş	Kızlarda	Erkeklerde
6 Yaş	6-6	5,9 Yaş	6,2 Yaş
	6+6	6,2 Yaş	6,4 Yaş
	1-1	6,3 Yaş	6,5 Yaş
7 Yaş	1+1	7,2 Yaş	7,5 Yaş
	2-2	7,3 Yaş	7,7 Yaş
8 Yaş	2+2	8,2 Yaş	8,3 Yaş
Ara Dönem		1,7 Yıl sürer	2,1 Yıl sürer
10 Yaş	3-3	8,2 Yaş	8,3 Yaş
	4+4	10,0 Yaş	10,4 Yaş
	4-4	10,2 Yaş	10,8 Yaş
11 Yaş	5+5	10,9 Yaş	11,2 Yaş
	5-5	10,9 Yaş	11,5 Yaş
	3+3	11,0 Yaş	11,7 Yaş
12 Yaş	7-7	11,7 Yaş	12,1 Yaş
	7+7	12,3 Yaş	12,7 Yaş
19 Yaş	8±8	17-25 Yaş arası	17-25 Yaş arası

2.2.4 Oklüzyon Gelişimi

Maksiller ve mandibular dişlerin birbirleriyle kapanışı anlamına gelen oklüzyon kafa kaidesi ve çenelerin gelişmesi, diş sürmesi gibi gelişimsel süreçlere bağlı mekanizmalarla ortaya çıkmaktadır.²⁸ Oklüzyonun gelişimi 7 evrede ele alınmaktadır.²⁹ Bunlar;

I. Dişsiz Dönem (0-6 ay):

Bireyin doğumundan ilk süt dişinin çıkmasına kadar geçen, ağız içerisinde hiç diş bulunmayan süreçtir.³⁶ Ancak nadiren doğum esnasında bireyin maksiller veya mandibular santral dişleri sürmüş olabilmektedir. Doğumla beraber ağız içerisinde bulunan bu dişlere natal diş adı verilmektedir. Birey doğduktan bir süre sonra süren dişlere ise neonatal diş adı verilmektedir. Bu dönemde süt dişleri, çene kemikleri içinde sıkışık bir biçimde bulunmaktadır. Alveol kemiğin uzayın üç yönünde de büyümesi ile hem dile hem de süt dişlerine sürme için gereken yer sağlanmaktadır.²⁹

II. Süt Dişlerinin Sürme Dönemi

Alveol kemiğinin büyümesini sağlayan en önemli etmen diş gelişimi ve diş sürmesidir. Bireyin doğumundan iki yaşına kadar olan süreçte alveol kemikte kanin uzunluğu ve kaninler arası mesafede bir artış gözlenir. Her iki çene için sagittal olarak ölçülen kanin uzunluk artışı 4 mm iken, kaninler arası mesafedeki artış maksillada 6 mm, mandibulada 3 mm olarak bildirilmiştir. Bu mesafelerdeki artışla görülen gelişmelerin bir sonucu olarak alveol kemik içerisinde sıkışık olarak yerleşmiş olan süt keser dişler ve kanin dişlerin sürmesi için çenelerde yer sağlanmış olur. Süt keser dişlerin, alveol kemik içerisinde daha labial konumlu sürmesiyle süt kesici ve kaninler aralarında diastema görülür. Süt dişlenmede yer darlığı ve çapraşıklık olması beklenmeyen bir durumdur. Süt dişlenmede, süt dişleri arasında %70 oranda generalize bir diastema görülür. Süt dişlerinin sürme döneminde, süt ikinci molar dişler hariç tüm süt dişlerin sürmesi iki yaşına kadar tamamlanmış olur.²⁹

III. Fonksiyonel Süt Dişi Dönemi

Bireyin doğumundan sonra geçen iki yılda meydana gelen çok hızlı büyüme ve gelişim döneminden sonra karışık dişlenme döneminin başlangıcına kadar, çenelerin

anterior bölgelerinde diş kavislerinde sagittal ve transversal boyutlar hemen hemen aynı kalmaktadır. Çenelerin posterior bölgelerinde ise maksiller süt dişi kavsi genişliğinde 1 mm'lik bir artış gözlenmektedir. Diş kavsi uzunluğunda ise her iki çene için yaklaşık 1 mm'lik bir azalma meydana gelmektedir. Bu dönemde mandibulanın öne doğru büyümesi ve süt dişlerinde görülen aşınma sonucunda süt kesiciler arasında başa baş bir kapanış ilişkisi gözlenmektedir.²⁹

IV. Karışık Dişlenme Dönemi

Daimi birinci molar dişlerin sürmesi ile başlayan, yirmi adet süt dişinin düşüp yerini daimi dişlere bırakmasıyla tanımlanan döneme karışık dişlenme dönemi adı verilmektedir.³⁶ Bu döneme karışık dişlenme dönemi adı verilmesinin sebebi çenelerde süt ve daimi dişlerin bir arada bulunmasıdır. Karışık dişlenme dönemi öncesinde 4-5 yaş civarında alveolar kemik içerisinde sürmemiş halde daimi dişler ve sürmüş süt dişleri olmak üzere 48 adet diş veya diş germi bulunmaktadır. Alveolar kemik gelişimi henüz tamamlanmamış olduğu için mezyodistal boyutları süt dişlerinden fazla olan daimi diş germeleri alveolar kemikler içerisinde sıkışık bir biçimde yer almaktadır. Karışık dişlenme dönemi kendi içerisinde üç dönem olarak ele alınmaktadır.²⁹

Bu dönemler; daimi birinci molar dişlerin sürmesi ile başlayan ve daimi keser dişlerin sürmeleri ile tamamlanan karışık dişlenmenin birinci dönemi (6-8,5 yaş arası), daimi keser dişlerin sürmelerinin tamamlanmasından daimi kanin ve premolar dişlerin sürme başlangıcına kadar devam eden ara dönem (8,5-10 yaş arası) ve daimi kanin ve premolar dişlerin sürmelerinin görüldüğü karışık dişlenmenin ikinci dönemidir (10-12 yaş arası).²⁹

V. On İki Yaş Dişlerinin Sürme Dönemi

On iki yaş dişleri, daimi ikinci premolarların sürmesini takiben yaklaşık 6 ile 9 ay arasında, önce mandibulada daha sonra maksillada sürmeye başlamaktadırlar. Maksillada tüber bölgesinin gelişmesi, mandibulada ise ramus anterior kenarında görülen rezorpsiyon ve linea mylohyoidea üzerindeki sürdükleri kemikte meydana gelen apozisyon ile on iki yaş dişlerine yer sağlanmaktadır. Ayrıca bu dönemde Leeway yer rezervlerinden de faydalanılmaktadır.²⁹

VI. Fonksiyonel Daimi Dişlenme Dönemi

Bu dönemde 13 ile 18 yaşları arasında daimi birinci molarların mezyale hareket etmesiyle mandibular arkta çapraşıklık miktarında bir artış gözlenmektedir. Ayrıca mandibulanın öne doğru hareketi henüz devam etmekteyken, maksillanın öne hareketinin tamamlanması sebebiyle, belirgin overbite varlığında, mandibular kesici dişlerde çapraşıklık gözlenebilmektedir. Bu çapraşıklık için bir olası sebep de her iki çenede de 16 yaşından sonra görülen kaninler arası mesafede gözlenen bir miktar azalıştır. Kesin olmamakla birlikte yirmi yaş dişlerinin sürme başlangıcı ile mandibular keser dişlerde görülen çapraşıklık arasında bir ilişki olduğu düşünülmektedir.²⁹

VII. Yirmi Yaş Dişlerinin Sürme Dönemi

Yirmi yaş dişlerinin folikülü, radyograflarda 8 yaşından itibaren izlenmeye başlamaktadır. Radyograflarla yapılan incelemelerde yirmi yaş dişlerinin kalsifikasyonun 10 yaşında başladığı, bifurkasyon oluşumunun ise 14 yaşından itibaren gözlenebildiği bildirilmiştir. Bu dişler 18 ile 24 yaşları arasında sürebilmektedirler. Yirmi yaş dişlerinde yarı gömülü veya tam gömülü olma gibi durumlara sıkça rastlanmaktadır. Bu durum, yirmi yaş dişlerinin çene kemiklerinin büyüme ve gelişiminden sonra sürmelerine bağlanmaktadır.²⁹

2.3 Dişlerin Yapısı ve Yaşla Gelişen Değişiklikler

2.3.1 Mine

Dişlerin ağız ortamında bulunan kısmını kaplayan, diş kronuna şekil, kontur ve koruyuculuk sağlayan mine dokusu, vücuttaki en sert kalsifiye matriks dokudur. Minenin oluşumundan sorumlu ameloblast hücreleri, diş ağız ortamına sürünce kaybolmaktadır. Bu sebeple mine, kendini yenileyemeyen bir doku olarak karşımıza çıkmaktadır. Bu doğal sınırlamayı telafi etmek için mine, karmaşık bir yapısal organizasyon ve organik matriksin neredeyse yok denecek kadar azlığı ile yüksek derecede bir mineralizasyon özelliği kazanmıştır.^{25,37}

Yüksek mineral içeriği mineyi aşırı derecede sert bir yapı haline getirmektedir. Bu karmaşık yapısal organizasyon minenin çiğneme sırasında uygulanan mekanik kuvvetlere dayanmasını sağlamaktadır. Ancak minenin gösterdiği bu sertlik aynı

zamanda mineyi daha kırılgan bir doku haline getirmektedir. Bu nedenle mine bütünlüğünü korumak için altta daha esnek olan dentin tabakasına ihtiyaç duyulmaktadır. Destekleyici görevdeki bu dentin tabakası çürük veya uygun olmayan kavite hazırlığı nedeniyle tahrip olursa, desteklenemeyen mine kolayca kırılmaktadır.³⁷

Mine yaklaşık olarak %96 mineral ve %4 organik madde ve sudan oluşmaktadır. Minenin inorganik içeriği, hidroksiapatit adı verilen, kemik, kalsifiye kıkırdak, dentin ve sementte de bulunan, karbonat iyonları ile süstitüsyona uğramış, kristal yapıda bir kalsiyum fosfattır $[Ca_{10}(PO_4)_6(OH)_2]$. Minenin oluşumu esnasında ortamda mevcutsa stronsiyum, magnezyum, kurşun ve florür gibi çeşitli iyonlar kristallere dahil edilebilmektedir. Bu kristallerin asitlerle çözünmeye karşı gösterdiği duyarlılık diş çürüklerinin kimyasal temelini oluşturmaktadır.³⁷

Minenin organik bileşeni ise, deri dokusunun da proteini olan keratine benzer nitelik taşıyan enamelindir. Bu yapının mine kristalleri arasında ve üzerindeki dağılımı, mine geçirgenliğine yardımcı olmaktadır.²⁵

Minenin temel organizasyon birimleri mine prizmaları ve interprizmatik minedir. Mine prizmaları altıgen olarak tanımlanmıştır ve 60 ila 70 nm genişliğinde ve 25 ila 30 nm kalınlığında, sıkı bir biçimde kenetlenmiş ve uzun, şerit benzeri hidroksiapatit kristallerinden oluşmaktadır. Mine dokusunun çiğneme kuvvetlerine karşı direnç gösteren yapısı, ameloblast hücrelerinin mine dokusunu birbirine anahtar deliği biçiminde kenetlenen çubuklar biçiminde sentezlemesi sayesinde karşımıza çıkmaktadır.^{25,37}

Mine dokusu, günlük olarak 4 µm kalınlığında tabakalar halinde sentezlenmektedir. Bu tabakalı birikimin bir sonucu olarak mine dokusunda inkremental çizgiler izlenmektedir. Tabakalı birikim yapılırken, haftalık ritimde bir duraksama gerçekleşmekte ve bu duraksama mine dokusunda bir ağacın enine kesitindeki halkalar benzeri bir görünüm oluşturmaktadır. Bu duraksama çizgilerine Retzius çizgisi adı verilmektedir. Retzius çizgileri, mine dokusunun tüm hacmi boyunca izlenmektedir. Mine yüzeyine gelindiğinde, Retzius çizgileri perikimata adı verilen sırtlar olarak ortaya çıkmaktadır. Neonatal çizgi ise, doğum esnasına meydana gelen büyük fizyolojik değişiklikleri açıkça yansıtan genişlemiş bir Retzius çizgisi

olarak karşımıza çıkmaktadır. Neonatal çizgiye benzer biçimde, diğer Retzius çizgilerinden daha belirgin olarak izlenen duraksama çizgileri, amelogenez sürecini etkileyen sistemik rahatsızlıklar (örn. ateşli hastalıklar) geçirildiğinde de izlenebilmektedir.²⁵

Minenin rengi grimsi beyazdır ancak yarı saydam olduğu için alttaki dentinin sarımsı renginin yansımalarıyla birlikte hafif sarı olarak görünmektedir. Minenin kalınlığı ise servikal kenarda bıçak benzeri bir kenarla başlayıp oklüzal veya insizal yüzeylerde yaklaşık 2.5 mm'lik maksimum kalınlığa kadar değişmektedir.²⁵

Yaşlanmayla minede bazı değişiklikler izlenmektedir. Mine atrizyon bölgelerinde aşınma göstermektedir. Yaşlı bireylerde bu aşınma fasetleri giderek daha belirgin hale gelmektedir. Yaşla beraber minede renk değişikliği, geçirgenlikte azalma ve yüzey tabakasında da bazı değişiklikler gerçekleşmektedir. Yarı saydam olan mine tabakasının yaşla beraber incilmesi, minenin organik materyal oranındaki artış, alttaki dentin tabakasının sekonder dentin birikimi nedeniyle kalınlaşması nedeniyle dişlerin rengi zamanla koyulaşmaktadır.³⁷

Mine dokusu yarı saydam bir zar gibi davranmaktadır. Suyun ve küçük moleküllerin, mine kristallerinin arasındaki gözeneklerden geçişine izin vermektedir. Ancak yaşla beraber, mine kristalleri daha fazla iyon kazanır ve gözenekler küçülür. Bu durum mine geçirgenliğinin azalmasına neden olmaktadır.³⁷

Minenin yüzey tabakasının bileşimi, hayat boyu devam eden, ağız ortamı ile mine dokusu yapısı arasındaki iyon değişimi nedeniyle değişmektedir. Özellikle yüzey tabakasındaki florür içeriği önemli miktarda artış göstermektedir. Bu artış iyatrojenik olarak topikal florür uygulamalarıyla da gerçekleşebilmektedir.³⁷

2.3.2. Dentin

Dentin, pulpa-dentin kompleksinin sert doku kısmıdır ve hacim olarak dişin büyük bölümünü oluşturmaktadır. Dentin dokusu, dentini oluşturan odontoblastların sitoplazmik uzantılarını içeren, dentin tübülleri ile karakterize kemik benzeri bir matrikstir. Odontoblastların hücre gövdeleri ise diş pulpasının periferik sınırını oluşturmakta ve dentinin iç yüzü boyunca hizalanmaktadır.³⁷

Dentin ilk önce, kalınlığı 10 ila 50 µm arasında değişen ve en içte dentinin pulpaya bakan kısmını kaplayan preentin adı verilen mineralize olmayan bir matriks tabakası olarak biriktirilmektedir. Preentin, esas olarak kolajenden oluşmaktadır. Kemikteki osteoid dokuya benzemektedir. Mineralize dentine göre daha az yoğun boyandığı için histolojik kesitlerde kolayca ayırt edilebilmektedir. Preentin, mineralizasyon cephesine çeşitli kolajen olmayan matriks proteinleri dahil edilerek, kademeli olarak dentin dokusuna mineralize olmaktadır. Dentinogenez sürecinde, kalsifiye preentin kadar yeni mineralize olmamış matriksin eklenmesiyle preentinin kalınlığı dengelenmektedir. Preentin, aktif dentinogenezin meydana geldiği süreçte maksimum kalınlıktadır ve yaşla birlikte kalınlığı azalmaktadır.³⁷

Matür dentin yaklaşık olarak %70 inorganik materyal, %20 organik materyal ve %10 sudan oluşur. Dentinin inorganik bileşeni, hidroksiapatitten oluşmaktadır. Organik faz, çeşitli kolajen olmayan matriks proteinleri ve lipidlerin fraksiyonel inklüzyonları ile yaklaşık %90 oranda kolajendir (esas olarak tip I ve tip III ve az miktarda tip V kolajen). Yapılan araştırmalarda uzun süredir kemiğe veya dentine özgü matriks proteinleri tanımlanmaya odaklanılmış olsa da araştırmaların sonucunda kemik matriks proteinlerinin dentinde ve dentin matriks proteinlerinin de kemikte bulunabileceği ortaya konmuştur.³⁷

Dentin, kemikten biraz daha sert ve mineden daha yumuşak bir dokudur. Bu fark, radyograflarda dentinin mineden daha radyolüsent ve pulpadan daha radyopak olarak izlenmesiyle kolaylıkla ayırt edilebilmektedir. Işık, ince, yüksek oranda mineralize olmuş mineden kolayca geçebildiğinden ve alttaki sarımsı dentin tarafından yansıtılabildiğinden, diş kronunun rengi bu duruma bağlıdır. Daha kalın mineye sahip olan dişlerde mine, ışığın kolayca geçmesine izin vermemekte, bu tür dişlerde kron daha beyaz görünmektedir. Pulpa hastalığı olan dişler, kök kanalları oblitere olmuş dişler veya kanal tedavisi görmüş pulpası olmayan dişlerde de sıklıkla dentin renginde bozulma görülmektedir. Bu durum klinik kron renginin daha koyu izlenmesine yol açmaktadır.³⁷

Fiziksel olarak dentin, dişin düzgün fonksiyon görebilmesini sağlayacak bir elastisiteye sahiptir. Bu elastikiyet dişin maruz kaldığı çiğneme kuvvetlerine esneklik sağlamakta ve üstteki minenin kırılmasını önlemektedir. Dentin ve mine, mikroskopik olarak iyi tanımlanmış, taraklı bir sınır olarak görünen mine-dentin birleşiminde

birbirlerine sıkıca bağlıdır. Diş kökünde dentin genellikle sement dokusu ile örtülmektedir ve bu iki doku arasındaki bağlantı mine-dentin birleşimine göre daha az belirgin olarak izlenmektedir.³⁷

Dentin-pulpa kompleksi, tüm vücut dokularında olduğu gibi zamanla bir dizi değişime uğramaktadır. En göze çarpan değişiklik, sekonder dentinin yaşla beraber sürekli olarak birikiminin neden olduğu pulpa odası ve kök kanalının hacmindeki daralmasıdır. Yaşlı dişlerde kök kanalı genellikle son derece ince olarak izlenmekte, hatta bazen kök kanalı neredeyse tamamen tıkanmış bir görünüm sergilemektedir. Pulpa hacmindeki bu tür devamlılık gösteren bir daralmanın, pulpanın vasküler beslenmesinde azalmaya neden olduğu ve bu dokudaki yaşlanma ile gerçekleşen değişiklik sürecini başlattığı düşünülmektedir.³⁷

Primer Dentin

Diş dokusunun çoğu, pulpa odasının ana hatlarını oluşturan ve sirkumpulpal dentin olarak adlandırılan primer dentin tarafından oluşturulmaktadır. Mine veya sementte yakın olan dış tabaka, mineralize olma şekli ve kolajen ile kolajen olmayan matriks bileşenleri arasındaki yapısal ilişki açısından primer dentinin geri kalanından farklılık göstermektedir. Bu dış tabaka manto dentin olarak adlandırılır. Bununla birlikte, manto dentin terimi genellikle koronal dentindeki mineye komşu, dış tabakaya atıfta bulunmak için kullanılmaktadır.³⁷

Sekonder Dentin

Sekonder dentin apozisyonu, kök oluşumu tamamlandıktan sonra başlayan ancak primer dentin yapımına kıyasla çok daha yavaş bir hızda gerçekleşen dentin birikimini temsil etmektedir. Sekonder dentinin, yapısı primer dentine göre daha az düzenli olmakla birlikte, primer dentinin tübüler yapısıyla devamlılık gösteren bir yapıya sahiptir. Mineral miktarının organik materyale oranı, primer dentin ile aynıdır. Sekonder dentin birikimi pulpa odasının çevresinde, özellikle molar dişlerde eşit düzeyde değildir. Sekonder dentinin pulpa odasının tavanında ve tabanında daha fazla birikmesi, pulpa odasının boyutunda ve şeklinde asimetric bir daralmaya yol açmaktadır. Sekonder dentindeki tübüler skleroz, primer dentinden daha kolay

gerçekleşmektedir. Bu durum, dentinin genel geçirgenliğini azaltmakta ve böylece pulpanın korunmasına yardımcı olmaktadır.³⁷

Tersiyer Dentin

Tersiyer dentin, çürük veya restoratif diş tedavisi gibi çeşitli uyaranlara tepki olarak üretilmektedir. Primer veya sekonder dentinin aksine, tersiyer dentin, yalnızca uyarıdan doğrudan etkilenen hücreler tarafından üretilmektedir. Üretilen tersiyer dentinin kalitesi, yapısı ve miktarı, uyarının yoğunluğuna ve süresine bağlı olarak başlatılan hücresel yanıtla ilgilidir. Tersiyer dentin, sekonder dentinin devamı niteliğinde tübüllere sahip olabilir. Sayıca seyrek ve düzensiz tübüllere sahip olabilir veya hiç tübül yapı göstermeyebilir. Tersiyer dentin, önceden var olan odontoblastlar tarafından oluşturuluyorsa reaksiyoner dentin, uyarı sonucu yeni farklılaşmış odontoblast benzeri hücreler tarafından oluşturuluyorsa reperatif dentin olarak adlandırılmaktadır.³⁷

2.3.3 Sement

Sement, diş köklerini kaplayan sert, avasküler bir bağ dokusudur.³⁷ Sementin kök dentin tübüllerini kapatmak ve dişi sokette tutmaya yarayan periodontal lifler için bir bağlantı görevi görmek olarak iki ana görevi vardır. Sement dokusu, yüzeyinde pürüzsüz bir yama oluşturan, çökelme yoluyla kök rezorpsiyonunu tersine çevirme yeteneğine sahip olan bir dokudur.²⁵

Sementin bileşimi kemiğe benzemektedir. Sement, ağırlıkça yaklaşık %45 ila %50 hidroksiapatitten, kalan kısmı ise kolajen ve kolajen olmayan matriks proteinlerinden oluşmaktadır. Tip I kolajen, sementin baskın kolajenidir. Sement dokusundaki organik bileşenlerinin %90'ını oluşturmaktadır. Tıpkı kemik dokuda olduğu gibi mineral birikiminin önemli bir bölümünü barındırmaktadır. Sementte bulunan kolajen olmayan proteinler ayrıca kemikle de ilişkilidir. Bunlar, alkalik fosfataz, kemik sialoproteini, dentin matriks proteini 1, dentin sialoprotein, fibronektin, osteokalsin, osteonektin, osteopontin, proteoglikanlar, proteolipidler, tenasin ve çeşitli büyüme faktörleri olarak sıralanabilir.³⁷

Diş köklerini iki tip sement dokusu kaplamaktadır. İlki, ara sement adı verilen ve iç epitel kök kılıfı hücrelerinden oluşan homojen bir tabakadır. Hücresel-aselüler

sement olarak adlandırılan ikincisi ise, diř folikülündeki farklılaşmamış hücrelerden gelişen sementoblastlar tarafından üretilen kemik benzeri bir maddenin daha kalın bir birikimidir. Bu katman, genellikle hücresiz bir katman birikimi ve ardından bir hücreli katman birikimi olmak üzere gerçekleşen artışlarla düzenlenir.³⁷

Sement dokusu, boşluklar içinde bulunan hücreleri ve kanalcıklar içindeki hücre prosesleri ile yapı olarak kemiğe çok benzer bir dokudur. Ancak yapı olarak kemiğe bezeyen bir doku olmasına rağmen kemiğin özelliđi olan vaskülariteye ve innervasyona sahip değildir. Bunun bir sonucu olarak sement, nöral hassasiyetten yoksunluk ve kemikten daha fazla rezorpsiyona direnç gösterme yeteneđi gibi özellikler kazanmıştır.³⁷

Yaşlanma ile sement yüzeyi, yüzey rezorpsiyonu ile daha düzensiz bir yüzey haline gelmektedir. Bu durum, bazı bađ lif demetlerinin sement yüzeyinde tutunduđu yerdeki kalsifikasyonundan kaynaklanmaktadır. Bu kalsifikasyonlar, sementte gömülü, sementte yapışık veya periodontal ligamette serbest konumda bulunabilmektedir. Bu tür oluşumlar sement yüzeyinin çođu kısmında görülebilmektedir. Ayrıca yaşlanmayla birlikte apikal bölgedeki sement artışının devam etmesi kök kanalında tıkanmaya sebep olabilmektedir.²⁵

Yaşlanmayla beraber görülen deđişikliklerden biri de sement rezorpsiyonudur. Sement rezorpsiyonu devamlılık gösteren bir süreç değildir. Bir süre aktif hale gelebilmekte ve sonra durabilmektedir. Yaşlanmayla birlikte diřin oklüzal seviyesinde bir azalma meydana gelmektedir. Diř, fonksiyonel oklüzyonda olması gerektiđinden bu azalma, periodontal ligament, alveolar kemik ve son olarak sementteki deđişikliklerle telafi edilmektedir.²⁵

2.3.4 Pulpa

Pulpa, diřlerin ortasında, dentin dokusunun iç kısmında yer alan ve onu destekleyen, ince duvarlı kan damarları, sinirler ve sinir uçları içeren hassas, özel bir gevşek bađ dokusudur.²⁵ Kapladığı boşluk, bir koronal kısım (pulpa odası) ve bir radiküler kısım (kök kanalı) içermektedir. Pulpa odası, anatomik kronun genel şekline uygundur.³⁷ Her bir pulpa, kök kanalının apeksi yoluyla diři çevreleyen doku olan periodonsiyuma açılmaktadır.²⁵

Pulpanın ana hücreleri, odontoblastlar, fibroblastlar, farklılaşmamış ektomezenkimal hücreler, makrofajlar ve diğer immünokompetan hücrelerdir. Ayrıca pulpa, uygun bir multipotent kök hücre kaynağıdır.³⁷

Pulpa, hem koronal hem de radiküler pulpada izlenen bir merkezi bölge ve bir periferik bölgeden oluşmaktadır. Merkezi bölge, apekten pulpaya giren ve koronal pulpa odasına ilerleyen arteriyoller, damarlar ve sinir gövdelerini içermektedir. Fibroblastlar, glikozaminoglikanlar ve kolajen liflerden oluşur. Hücre dışı matrikste en çok bulunan hücredir. Odontoblastlar ise ikinci en yaygın hücre olarak izlenmektedir. Periferde bulunan odontojenik bölge ise odontoblastlardan, hücresiz ve hücreden zengin bölgeden oluşmaktadır. Hücreden zengin bölgenin bitişiğinde parietal bir sinir tabakası bulunmaktadır.²⁵

Pulpa dokusu, biçimlendirici, koruyucu, besleyici ve onarıcı faaliyetler gibi çeşitli işlevlere sahiptir. Tüm bu klinik özellikler dişlerin bakımı ve onarımı yönünden önem arz etmektedir. Odontoblastların yaşam boyunca dentin oluşturması, pulpanın zamanla daralmasına neden olmaktadır. Yaşlanma ile görülen fibrozis ve kolajen lif demetlerindeki artışla pulpadaki bu daralma gittikçe daha belirgin bir hal almaktadır. Yaşlanma ve zaman içerisinde diş gelen mikro travmaların bir sonucu da pulpa dokusunu oluşturan hücrelerdeki morfolojik değişimdir. Bu değişiklikler hücresel stoplazma hacminin azalması, endoplazmik retikulum ve mitokondri gibi organellerin sayılarının azalması olarak sıralanabilir. Dolayısıyla, yaşlanmış bir pulpa dokusu, daha az hücreli, daha fibröz yapıda ve daha az vaskülarizasyon gösteren bir yapı göstermektedir. Bu generalize azalma, hücresel aktivitedeki azalmanın da bir göstergesidir ve pulpa dokusunu hasarlanmaya karşı daha hassas hale getirmektedir. Onarım kapasitesinin azalması, pulpanın hasarlara verilen cevabındaki yeteneğin azalmasına sebep olmaktadır.²⁵

2.4 Çocuklarda ve Adölesanlarda Yaş Tahmin Metotları

2.4.1 Schour ve Massler Metodu

Schour ve Massler³⁸, 1941 yılında diş gelişimi üzerine yayımladıkları çalışmalarında, intrauterin hayatın beşinci ayından otuz beş yaşa değin süt ve daimi dişlerin beklenen gelişim evrelerini bir diyagram haline getirmiş, alt ve üst çeneden

alınan çeşitli intraoral/ekstraoral radyograflar ve intraoral fotoğraflar bu diyagramlarla karşılaştırılmıştır. Bu yöntemde dişlerin gelişimi kronolojik olarak yirmi iki ayrı aşama halinde şematize edilmiş ve diş gelişimi morfolojik olarak değerlendirilmiştir.³⁸

2.4.2 Gleiser ve Hunt Metodu

Gleiser ve Hunt³⁹, 1955 yılında 25 kadın ve 25 erkek katılımcı üzerinde gerçekleştirdikleri çalışmalarında, yenidoğan dönemden on sekiz aylık döneme kadar olan gruptan üç ay arayla, on sekiz aylıktan on yaşa kadar olan gruptan altı ay arayla alınmış ekstraoral lateral çene grafilerini değerlendirmiş ve mandibular daimi birinci molar dişin kalsifikasyon aşamalarını incelemiştir. Yaş tahmini yapılabilmesi için mandibular daimi birinci molar dişi gelişim aşamalarına göre on altı ayrı aşamada inceleyen Gleiser ve Hunt, bu aşamalara ait standart sapmayı ve ortalama yaşı hesaplayarak bir tablo oluşturmuşlardır. Araştırmacılar bu çalışmalarında kadın ve erkek bireylerin diş gelişimlerinin yaklaşık olarak benzer hızda olduğunu bildirmişlerdir. Yaş tahmini yapılması için tek bir dişin referans alınması nedeniyle, o dişte gelişebilecek herhangi bir patolojik durum bu yöntemin kullanılmasını engellemektedir.³⁹

2.4.3 Nolla Metodu

Carmen Nolla'nın⁴⁰ 1960 yılında yaptığı çalışmasında, yaşları 2 ile 17 arasında değişen 25 kadın ve 25 erkek katılımcının yıllık olarak ekstraoral lateral çene grafileri, maksiller ve mandibular oklüzal radyografları ve posterior dişlerin intraoral radyografları alınmıştır. Toplamda, kadınlara ait 1746 erkeklere ait 1656 adet radyograf üzerinden başın yalnızca sağ ya da sol olarak tek tarafındaki alt ve üst çene dişleri değerlendirilmiştir. Maksiller ve mandibular üçüncü molar dişler çalışmanın kapsamı dışında tutulmuştur. Yöntem kadınlar ve erkekler için ayrı ayrı oluşturulmuş tablolarla, alınan radyograflar üzerinden her bir dişin gelişiminin başlangıcından kök gelişiminin tamamlanıp apekslerin kapanmasına kadar olan sürecin on aşamada incelenmesi ve 0 ile 10 arasında puanlanmasına dayanılarak gerçekleştirilmektedir. Alınan radyograflar üzerinden maksiller ve mandibular 7 diş için ayrı ayrı puanlama yapılmış ve toplam değer diş gelişim skoru olarak ifade edilmiştir. Nolla metodunda dişlerin gelişim aşamaları Tablo 2.3'teki gibi tarif edilmiştir.⁴⁰

Tablo 2.3 Nolla metoduna ait diş gelişim aşamaları

10	Kök gelişimi tamamlanmış ve apeks kapanmış
9	Kök gelişimi neredeyse tamamlanmış ancak apeks açık durumda
8	Kökün üçte ikisi tamamlanmış
7	Kökün üçte biri tamamlanmış
6	Kron oluşumu tamamlanmış
5	Kron oluşumu hemen hemen tamamlanmış
4	Kron oluşumunun üçte ikisi tamamlanmış
3	Kron oluşumunun üçte biri tamamlanmış
2	Kalsifikasyon başlangıcı
1	Kripta varlığı
0	Kripta yok

2.4.4 Moorrees, Fanning ve Hunt Metodu

Moorrees ve arkadaşlarının⁴¹ 1963 yılında lateral ve oblik çene grafileri üzerinde gerçekleştirdikleri çalışmalarında diş gelişimi, tüberkül oluşumunun başlamasından, apekslerin kapanmasına kadar alt ve üst çenedeki sekiz kesici diş kullanılarak, on dört ayrı aşamada ve her iki cinsiyet için ayrı tablolar oluşturularak değerlendirilmiştir.

2.4.5 Anderson, Thomson ve Popovich Metodu

1976 yılında ortaya konan bu yöntemde, Moores ve arkadaşları⁴¹ tarafından 1963 yılında yapılan çalışma esas alınıp geliştirilerek, 111 kadın ve 121 erkek katılımcıdan yıllık olarak alınan sefologramlar üzerinden diş gelişimi evrelenmiştir. Alt ve üst çenelerin her ikisi için ayrı ayrı standart sapma ve ortalama yaş hesaplanmıştır. Doğumdan üç yaşa kadar olan sürecin bu çalışmanın kapsamı dışında olması yöntemin limitasyonu olarak bildirilmektedir.⁴²

2.4.6 Mörnstaad, Staaf ve Welander Metodu

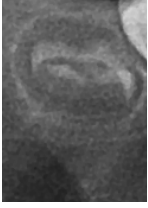
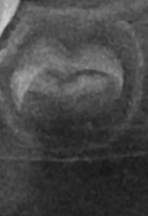
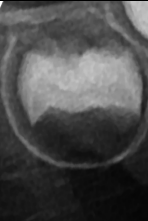
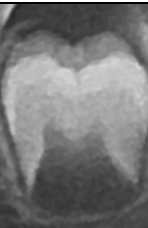
Mörnstaad ve arkadaşlarının⁴³ 1994 yılında yaptığı çalışmada, 5,5 ile 14,5 yaş arasındaki 270 erkek ve 271 kadın katılımcıya ait panoramik radyograflar dijital ortama aktarılmış ve dişlerin gelişim aşamalarına göre çeşitli ölçümler gerçekleştirilmiştir. Bu ölçümler; dişlerin kron uzunluklarını, molar dişlerde mezyal ve distal köklerin uzunlukları ve apeks genişliklerini, tek köklü dişlerin kök uzunluğunu ve apeks genişliğini içermektedir. İlgili kronolojik yaşa ait radyograflar üzerinden elde edilen metrik ölçüm verileriyle çoklu regresyon modeli

oluşturulmuştur. Kronolojik yaş ile ölçümler arasındaki korelasyon test edilmiştir. Çalışmanın sonucunda, yaş tahmininde %95 aralığında ± 2 yaş standart sapma bildirilmiştir.⁴³





2.4.7 Demirjian Metodu

1973 yılında Demirjian ve arkadaşlarının⁴⁴, 1446 erkek ve 1482 kadın katılımcı üzerinde gerçekleştirdikleri çalışmada diş gelişimi, panoramik radyograflar üzerinden morfolojik olarak değerlendirilmiştir. Yöntemin ilk basamağında, daimi sol mandibular yedi dişin mineralizasyon evreleri sekiz kategoriye ayrılmaktadır. Demirjian metoduna ait gelişim aşamaları Tablo 2.4'te sunulmuştur. Yöntemin ikinci basamağında ise her bir gelişim evresine karşılık gelen kadın ve erkekler için ayrı sayısal değerler toplanarak bir gelişim skoru elde edilmektedir. Elde edilen gelişim skoru, kadınlar ve erkekler için oluşturulmuş tablolarla karşılaştırılarak ilgili skora karşılık gelen yaş aralığına göre bireyin yaş tespiti gerçekleştirilmektedir.⁴⁴

Tablo 2.4 Demirjian metoduna ait gelişim aşamaları

	1. Evre (A): Hem tek köklü hem de çok köklü dişlerde, tüberkül tepelerinde ters çevrilmiş bir koni veya koniler şeklinde kripta seviyesinde kalsifikasyon başlamaktadır.
	2. Evre (B): Kalsifikasyon noktalarının kaynaşması ile ana hatları çizilebilen düzenli bir oklüzal yüzey oluşturmak üzere birleşen bir veya birkaç tüberkül oluşmaktadır.
	3. Evre (C): Mine formasyonu, kronun oklüzal ve insizal yüzeylerinde tamamlanmıştır. Dentin dokusu belirlemeye başlar, pulpa odasının ana hatları izlenmektedir.
	4. Evre (D): Kron formasyonu, sement ile mine birleşim noktasına kadar tamamlanmıştır. Pulpa odası, tek köklü dişlerde eğimli konkav bir şekildedir. Molar dişlerde ise ikizkenar yamuk şeklindedir ve kök formasyonu görülmeye başlamaktadır.

Tablo 2.4 devam Demirjian metoduna ait gelişim aşamaları

	<p>5. Evre (E): Pulpa odası duvarı düz çizgi şeklini almakta ve pulpa boynuzlarının devamlılığında bozulma izlenmektedir. Kök uzunluğu kron yüksekliğinden azdır. Molar dişlerde bifurkasyonun başlangıç formasyonu kalsifiye noktalar veya yarım ay şeklinde izlenebilmektedir.</p>
	<p>6. Evre (F): Pulpa odası tek köklü dişlerde ikizkenar üçgen formunu almaktadır. Hem tek köklü hem çok köklü dişlerde kök uzunluğu, kron uzunluğuna eşit ya da daha büyüktür ve kök kanalının apikal ucu huni şeklinde sonlanmaktadır. Çok köklü dişlerde bifurkasyon bölgesindeki kalsifikasyon aşağıya doğru ilerler, yarım ay şekli kesin ve belirgindir.</p>
	<p>7. Evre (G): Kök kanal duvarları paralel görünümündedir ve kök kanalının apikal ucu kısmen açıktır.</p>
	<p>8. Evre (H): Kök kanalının apikal ucu tamamen kapalıdır. Periodontal membran, kök ve apeks çevresinde üniform genişliğe sahiptir.</p>

2.4.8 Willems Metodu

Guy Willems² tarafından geliştirilen bu metot, Demirjian metodunun diş gelişim aşamaları esas alınarak her iki cinsiyet için ayrı tablolar oluşturulması ve tek yönlü varyans analizi uygulanması ile revizyonuna dayanmaktadır. Demirjian metodunda olduğu gibi sol yedi mandibular daimi dişin mineralizasyon evrelerine kadınlar ve erkekler için ayrı sayısal değerler atanmıştır. Ancak bu yöntemde dişlerin gelişim evrelerine karşılık gelen skorların toplamı direkt olarak bireyin tespit edilen yaşını vermektedir.²

2.4.9 Cameriere Metodu

2006 yılında Cameriere ve arkadaşları⁴⁵ tarafından, yaşları 5 ile 15 arasında değişen 213 erkek ve 242 kadın katılımcıdan alınan panoramik radyografların analiziyle gerçekleştirilen bu çalışmada, alınan radyograflar bir tarayıcı kullanılarak sayısallaştırılmış ve görüntüler bilgisayar destekli bir çizim programı kullanılarak bilgisayar dosyalarına kaydedilmiştir. Sol yedi mandibular daimi dişin metrik ölçüleri yapılarak dişlere sayısal değer verilmiştir. Kök gelişimi tamamlanmış ve köklerin apikal uçları tamamen kapalı diş sayısı hesaplanmıştır. Ayrıca kök gelişimi tam olmayan, apeksleri açık olan dişler değerlendirilmiştir. Tek köklü dişlerde açık apeksin iç kısımları arasındaki mesafe ölçülmüştür. Çok köklü dişler için, açık apekslerin iç kısımları arasındaki mesafelerin toplamı değerlendirilmiştir. Olası magnifikasyon ve angulasyonların ölçümlere olan etkisini hesaba katmak için, yapılan ölçümler diş uzunluğuna bölünerek normalize edilmiştir. Son olarak, sol yedi mandibular daimi dişin normalize edilmiş ölçümleri, normalize edilmiş açık apeks(ler)in toplamı ve gelişimi tamamlanmış apeks sayısının toplamı kullanılarak dental olgunluk skoru hesaplanmış ve yapılan regresyon analizi ile formülize edilmiştir.⁴⁵

2.5 Yetişkin Bireylerde Dişlerde Yaşa Bağlı Oluşan Değişikliklere Göre Uygulanan Yaş Tahmin Metotları

2.5.1 Gustafson Metodu

Yetişkinlerde yaşa bağlı değişikliklerin değerlendirilmesiyle diş yaşının tespiti için ilk bilimsel yöntem 1950 yılında Gustafson⁴⁶ tarafından ortaya konmuştur. Gustafson yaptığı çalışmasında, yaş ile meydana gelen değişikliklerin ayrı ayrı değerlendirildiğinde yaş ile olan korelasyonunun zayıf olduğunu, ancak bir arada değerlendirildiğinde yaş tespitinde faydalı olacağını belirtmiştir. Bu amaçla dişleri atrizyon, sekonder dentin apozisyonu, periodontitis nedeniyle ataşmanlarında meydana gelen yapısal değişiklikler, sement apozisyonu, kök rezorpsiyon miktarı ve kök transparanlığı olmak üzere altı parametre üzerinden değerlendirilmiştir. Bu yöntemde incelenecek dişlerin mezyal ve distal yüzeylerinden 0,1 ve 0,25 mm'lik kesitler hazırlanmış ve mikroskop altında değerlendirme yapılmıştır. Belirlenen altı parametre üzerinden 0,1,2,3 şekilde skorlama yapılmıştır. Bu metotta skorların

toplanmasıyla elde edilen puanın oluşturulan regresyon doğrusuyla kesişim noktası tahmin edilen yaşı vermektedir.⁴⁶

2.5.2 Lamendin Metodu

Lamendin ve arkadaşları⁴⁷ tarafından 1992 yılında, yaşları 22 ile 90 arasında değişen 135 erkek ve 73 kadın katılımcı ile yapılan çalışmada, dişin kökündeki transparanlık miktarı ve periodontitis miktarı olmak üzere iki temel ölçüm kullanılmaktadır. Metot tek köklü bir diş üzerinde hiçbir müdahalede bulunulmadan yalnızca dişe alttan ışık tutmak suretiyle dişin bukkal yüzünden her bir diş için periodontitisten etkilenmiş kısmın ölçümü, kron boyu ölçümü yapılarak bu ölçümlerin Lamendin'in geliştirdiği formüle yansıtılması ile gerçekleştirilmektedir.⁴⁷

2.5.3 Atrizyon Metodu

Dişlerde yaşa bağlı değişikliklerden en belirgin olanı dişlerin oklüzal yüzeyleri ve insizal kenarlarında görülmekte olan atrizyondur. Atrizyonun yaş ile olan ilişkisini değerlendirmek için literatürde çeşitli derecelendirme sistemleri geliştirilmiştir. Molnar⁴⁸ adlı araştırmacının 1971 yılında geliştirdiği yöntemde, çeşitli toplumlara ait diş dizilerindeki dişler, atrizyon yönünden açısal olarak değerlendirilmiş ve skorlanmıştır.

Ball⁴⁹ adlı araştırmacı, sosyal alışkanlıkların ve beslenme biçimi gibi pek çok parametrenin dişlerin aşınma miktarlarını etkileyebileceğini öne sürmüştür. Ayrıca dentisyondaki tüm dişlerin birbirleriyle temasta olmadığını, dolayısıyla temasta olmayan dişlerin de aşınmaya uğramayacağını bildirmiştir. Sonuç olarak atrizyonun, tek değerlendirme parametresi olarak kullanıldığında yaş tahmininde hatalı sonuçlarla karşılaşılabilceğini bildirmiştir.⁴⁹

İşcan ve Steyn⁵⁰, atrizyonun çok sayıda parametreden etkilenmesi nedeniyle yaş tahmini çalışmalarında kullanılması durumunda, tüm diş dizisinin oklüzyon ve artikülasyon yönünden incelenmesi gerektiğini ve bir ya da birkaç dişin atrizyon derecesini değerlendirerek yaş tahmini yapılmaması gerektiğini bildirmişlerdir.⁵⁰

2.5.4 Kök Transparanlığına Göre Metotlar

Sklerotik dentinin yaşam boyu artışı, dentin dokusu genelinde bir transparanlığa neden olmaktadır. Dentindeki bu transparanlık artışı tamamen fizyolojik bir olgudur ve yaşamın genellikle üçüncü dekatından sonra izlenmektedir.⁵¹

Dentin transparanlığının yaş ile ilişkisini ilk olarak 1950 yılında Gustafson değerlendirmiştir.⁴⁶ Daha sonra dentin transparanlığı ile yaş arasındaki ilişki Bang ve Ramm⁵² tarafından da değerlendirilmiştir. Araştırmacılar, çalışmalarında kök transparanlığı artışı ile yaşlanma arasında anlamlı ilişki bildirmişlerdir.⁵² Solheim⁵³ tek köklü dişler ile gerçekleştirdiği çalışmasında yaş ile kök transparanlığı arasındaki ilişkinin popülasyona özgü olduğunu, yaş tahmini yapılabilmesi için çeşitli popülasyonlar üzerinde çalışmalara ve regresyon modellerine ihtiyaç duyulduğunu ifade etmiştir. Afşin ve arkadaşları⁵⁴ da kök transparanlığı ve yaş arasındaki ilişkiyi değerlendirmişler, bu iki parametre arasında anlamlı bir ilişki tespit etmişlerdir.

2.5.5 Sement Apozisyonuna Göre Metotlar

Yaşla birlikte sement apozisyonunun artması ve bu artışın ölçülebilirliği esasına dayanan bu yöntemde diş kökünden elde edilmiş kesitler değerlendirilmiştir.

Solheim⁵⁵ sement kalınlığı ile yaş arasındaki ilişkiyi incelemiş, inceleme için kullanılan diş tiplerinin sonucu etkilediğini, maksiller premolar dişler haricindeki dişlerin apikal 1/3'lük kısmından alınan kesitlerdeki vestibül ve palatinal yüzeylerdeki sement kalınlığının toplamının yaş ile en yüksek korelasyonu gösterdiğini bildirmiştir.

Stott ve arkadaşlarının⁵⁶ gerçekleştirdiği çalışmada, sement dokusunda görülen inkremental çizgilerin sayısı ile yaş arasındaki ilişki değerlendirilmiştir. Araştırmacılar, tespit edilen yaş ile kronolojik yaş arasında istatistiksel olarak yüksek bir uyum bulunduğunu bildirmişlerdir.⁵⁶

Ancak literatürde bu çalışmaların aksine, sement apozisyonunun yaşı değerlendirmede tek başına güvenilir bir kriter olmadığını bildiren yayınlar da mevcuttur.⁵⁷ Renz ve Radlanski⁵⁸, 2006 yılında gerçekleştirdikleri çalışmalarında, dişlerin farklı yüzeyleri üzerinden yapılan değerlendirmelerin farklı sonuçlar verdiğini ve inkremental çizgilerin sayılarının tespitinde güçlükler görüldüğünü bildirmişlerdir.

2.5.6 Aspartik Asit Rasemizasyonuna Göre Metotlar

Aminoasitler, proteinlerin temel yapıtaşdır. Doğada yirmi çeşit aminoasit bulunmaktadır. Vücutta bulundan proteinler ilk sentezlendiklerinde yalnızca L-enantiyomerleri içerir ve rasemizasyon adı verilen bir kimyasal reaksiyon ile yaşla beraber yavaş bir şekilde D-enantiyomerlerine dönüşür. Bu süreç ölümden sonra da devam etmektedir. Aspartik asit ise aminoasitler içerisinde en çok rasemizasyona uğrayan protein olup vücutta beyin, kemikler, göz lensi ve dişlerde bulunmaktadır.⁵⁹

Literatürde Helfman⁵⁹, Ritz⁶⁰, Benesova⁶¹ ve Carolan⁶² gibi araştırmacılar tarafından gerçekleştirilmiş, dentin dokusundaki aspartik asit rasemizasyonu ile yaş arasındaki ilişkiyi inceleyen araştırmalar mevcuttur.

Gerçekleştirilen çalışmalarda aspartik asit rasemizasyonu ile yaş arasında pozitif bir korelasyon bildirilmesine rağmen metodolojik farklılıklar nedeniyle bildirilen rasemizasyon oranları ve yaş tahminlerinde tutarsızlıklar izlenmiştir. Bu sebeple, Waite ve arkadaşları⁶³, rasemizasyon çalışmalarında fikir birliğine varılmasını ve uluslararası standart bir yöntem geliştirilmesini tavsiye eden bir çalışma yayınlamışlardır.

2.5.7 Radyoaktif Karbon 14'e Göre Metotlar

1955 yılına kadar doğada çok az ve sabit miktarda bulunduğu bilinen Karbon-14 izotopunun miktarı, dünya genelinde yapılan nükleer çalışmaların bir sonucu olarak ciddi bir artış göstermiştir. Karbon-14 izotopu oksijen ile kimyasal reaksiyona girerek radyoaktif karbondioksit molekülünü oluşturmakta ve dokularda bu formda birikim oluşturmaktadır. Buradan hareketle dişlerdeki karbon-14 konsantrasyonunun belirlenmesine dayanan ve o incelenen dental yapının hangi yılda oluştuğunu tespit etmeye yönelik bir yöntem geliştirilmiştir.⁶⁴

2.5.8 Telomer Kısalmasına Göre Metotlar

Telomerler, ökaryotik canlıların kromozomlarının terminal uçlarında bulunan, özelleşmiş heterokromatik yapılar olarak tanımlanır. Hücreler bölündükçe telomer boyları kısalmakta ve hücreler yaşlılık evresine girmektedirler. Literatürde, Ren⁶⁵ ve Johnson⁶⁶ gibi araştırmacılar tarafından, yaş ile telomer uzunluğundaki kısalma

arasındaki ilişkinin incelendiği çalışmalar gerçekleştirmiş ve güçlü korelasyon değerleri bildirilmişlerdir.

Takasaki ve arkadaşlarının⁶⁷ 2003 yılında gerçekleştirdikleri çalışmada, pulpa dokusundan alınan örnekler ile gerçekleştirilen DNA analizi sonucu, telomer kısalması ile yaş arasında istatistiksel olarak anlamlı bir ilişki olduğu bildirilmiştir.

2.5.9 Sekonder Dentin Birikimine Göre Metotlar

Sekonder dentin birikimi hayat boyunca devam eden bir süreçtir ve araştırmacılar tarafından yaş tayini için önemli bir parametre olarak kabul edilmektedir. Literatürde Gustafson⁴⁶, Woods ve arkadaşları⁶⁸, Kvaal ve arkadaşları⁶⁹, Cameriere ve arkadaşları⁷⁰ tarafından sekonder dentin dokusuna ait ölçümlerle gerçekleştirilen birçok çalışmada yaş ile sekonder dentin birikimi arasında istatistiksel olarak anlamlı ilişki olduğu bildirilmiştir.

2.5.10 Diğer Metotlar

Literatürde yaş tahmini üzerine klasik metotlara ek olarak, yaş ile dişlerin renk değişimine uğramasını ve dentin tübüllerinde gelişen değişimleri temel alan birçok çalışma vardır.⁷¹⁻⁷⁵ Martin-de las Heras ve arkadaşlarının⁷¹ 2003 yılında, yaşları 10 ila 89 arasında değişen hastalara ait 250 dişin kök dentinine ait rengin spektrometri ile değerlendirildiği çalışmada, dişlerin yaşla beraber çeşitli kolorometrik değişimler gösterdiği, bunun yanı sıra geliştirilen çoklu regresyon modelleri kullanılan dişin tipinin ve cinsiyetin istatistiksel olarak sonuçları etkilemediği bildirilmiştir. Lackovic ve Wood⁷² da diş rengi ile yaş arasındaki ilişkiyi değerlendirmiş yüksek korelasyon değerleri bulmuşlardır. Solheim⁷³, Kvaal ve arkadaşları⁷⁴, Amariti ve arkadaşları⁷⁵ ise dentin tübüllerindeki değişim ile yaş arasındaki ilişkiyi değerlendirmiş ve güçlü korelasyon değerleri bildirmişlerdir.

2.6 Yetişkin Bireylerde Radyograflar Üzerinden Gerçekleştirilen Yaş Tayini Metotları

2.6.1 Drusini Metodu

Drusini⁷⁶ ilk olarak 1993 yılında periapikal radyograflar üzerinden premolar ve molar dişlerin pulpa odası ve kron boyu uzunluklarını ölçmüştür. Koronal indeks adını verdiği bir formül (pulpa odasının uzunluğu x 100 / kron uzunluğu) geliştirmiştir.⁷⁶

Drusini ve arkadaşlarının⁷⁷, 1997 yılındaki çalışmasında ise bütün dişlerin tek bir radyograf üzerinden değerlendirilmesini sağlaması, rutin dental muayeneler esnasında sıklıkla kullanılması sebebiyle panoramik radyograflar kullanılmış, premolar ve molar dişlere ait koronal indeksler üzerinden regresyon modelleri oluşturulmuştur.

2.6.2 Cameriere Metodu

Cameriere ve arkadaşlarının⁷⁰ 2004 yılında yaşları 18 ile 72 arasında değişen 100 katılımcı ile gerçekleştirdikleri çalışmada, maksiller kanin dişlerin görüntüleri panoramik radyograflar üzerinden bilgisayar destekli bir çizim programına aktararak incelenmiştir. İncelenen her bir dişin dış sınırından 20, pulpasının dış sınırından ise 10 nokta belirlenmiştir. Belirlenen bu noktalar ile dişin ve pulpanın iki boyutlu görüntüde kapladığı alan hesaplanmıştır. Görüntü üzerinde dişin toplam uzunluğu, pulpanın boyu ve kök boyu ölçümleri yapılmıştır. Ayrıca üç farklı seviyeden pulpa ve kök genişlikleri de ölçülmüştür. Yapılan ölçümler üzerinden dişin pulpa uzunluğu/kök uzunluğu, pulpa uzunluğu/diştir toplam uzunluğu, üç farklı seviyede pulpa genişliği/kök genişliği ve pulpa alanı/diştir toplam alanı oranları hesaplanmıştır. Hesaplanan bu oranlar ile çoklu regresyon modelleri oluşturulmuş ve diş yaşı tahmini yapılmıştır.⁷⁰

2.6.3 Kvaal Metodu

Kvaal ve arkadaşlarının⁶⁹ 1995 yılında gerçekleştirdikleri çalışmalarında, yaşları 20 ile 87 arasında değişen 100 katılımcıdan paralel teknikle alınan periapikal radyograflar üzerinden stereo mikroskop ve kumpas kullanarak incelemelerde bulunmuşlardır. Alınan radyograflar üzerinden dişin pulpa uzunluğu/kök uzunluğu, pulpa uzunluğu/diştir toplam uzunluğu, dişin toplam uzunluğu / kök uzunluğu ve üç

farklı düzeyde pulpa genişliği/kök genişliği oranları hesaplanmıştır. Hesaplanan bu oranlar ile doğrusal regresyon modelleri oluşturulup diş yaşı tahmini yapılmıştır. Yapılan bu çalışma sonucu yaş ile en güçlü korelasyon gösteren dişler mandibulada lateral, kanin ve birinci premolar dişler ve maksillada santral, lateral ve ikinci premolar dişler olarak tespit edilmiştir.⁶⁹

2.6.4 Diş ve Pulpa Hacmi Kullanılarak Geliştirilen Metotlar (Üç Boyutlu Ölçümler)

Bireylerin hayatları boyunca devam eden sekonder dentin apozisyonu, pulpa yüzeylerinde eşit olarak gerçekleşmemektedir ve yaşla beraber pulpa odası tüm boyutlarda hacimsel olarak daralmaktadır. Ancak, eşit düzeyde olmayan bu üç boyutlu daralımı iki boyutlu görüntü oluşturan radyograflarla tespit etmek mümkün olmamaktadır.^{78,79} Son yıllarda teknolojinin gelişmesiyle birlikte konik ışıklı bilgisayarlı tomografi (KIBT) ve mikro-bilgisayarlı tomografi (mikro-BT) gibi üç boyutlu görüntüleme teknikleriyle pulpa ve diş hacimlerinin yaş ile ilişkisini ortaya koyan çalışmalar mevcuttur.

Vandevoort ve arkadaşlarının⁸⁰ 2004 yılında gerçekleştirdikleri çalışmalarında, tek köklü dişlere ait mikro-BT görüntüleri üzerinden diş/pulpa hacmi hesaplanmış ve yaş tahmini gerçekleştirilebilmesi için regresyon analizi uygulamışlardır.⁸⁰

Someda ve arkadaşlarının⁸¹ 2009 yılında gerçekleştirdikleri çalışmalarında, 155 adet mandibular keser dişin farklı bölümlerindeki hacimlerini mikro-BT görüntüleri üzerinden hesaplamış ve regresyon modelleri oluşturmuşlardır.

Aboshi ve arkadaşlarının⁸² 2010 yılında gerçekleştirdikleri çalışmalarında, 40 adet mandibular premolar dişin mikro-BT görüntüleri üzerinden pulpa/diş hacim oranlarına dayalı bir yaş tahmin metodu bildirmişlerdir.

Yang ve arkadaşları⁸³, 2006 yılında KIBT kullanarak gerçekleştirdikleri çalışmalarında pulpa/diş hacmi oranının yaş ile olan ilişkisi incelenmiş ve biyolojik yaş ile pulpa/diş hacim oranı arasında orta derecede bir korelasyon bildirmişlerdir.

Pinchi ve arkadaşları⁸⁴, 2015 yılında KIBT kullanarak pulpa/diş hacim oranlarını özel bir yazılım yardımıyla hesapladıkları çalışmalarında, bu oranlar

üzerinden lineer regresyon analizi gerçekleştirilmiş ve yaş tahmininin 30-59 yaş grubu bireylerde en yüksek doğruluk oranına ulaştığını bildirmişlerdir.⁸⁴

2.7 Dişlerden Yaş Tayini Yapılırken Kullanılan Radyograflar

2.7.1 Periapikal Radyograflar

Periapikal radyograflar ile dişlerin kronundan kök ucuna kadar tam boyutunu, lamina durayı, periodontal aralığı, kök etrafındaki ve interdental kemik yapısını değerlendirmek mümkündür. Periapikal radyograflar çekilirken paralel teknik ve açığortay tekniği olmak üzere iki temel projeksiyon tekniği kullanılmaktadır. Bu iki teknikte de x-ışını kaynağı, belli açıldırılmalar ile konumlandırılarak, diş yapısının aslına uygun ve net görüntüler elde edilmektedir. Açığortay tekniği uygulama kolaylığı sebebiyle, paralel teknik ise distorsiyonun minimum olması sebebiyle tercih edilmektedir.⁸⁵

2.7.2 Panoramik Radyograflar

Panoramik radyograf tekniği, her iki çenenin ve dişlerin tamamını, maksiller sinüslerin ise 1/3'lük bölümünün tek bir radyograf üzerinde görüntülenmesini sağlayan bir tekniktir. Rutin dental muayeneler esnasında sık kullanılan panoramik radyograflar; yüzü oluşturan kemiklerin ve dişlerin genel bir görüntüsünü oluşturmaları, tekniğin uygulanmasının kolay olması, görüntü oluşumunun hızlı olması, hastanın aldığı dozun düşük olması, trismus olan veya intraoral radyograf tekniklerini tolere edemeyen hastalarda da kullanılabilirliğinin olması gibi avantajlara sahiptir. Bunun yanı sıra intraoral radyografların sağladığı kadar ince detayların elde edilememesi, görüntüde oluşan süperpozisyonlar, hayalet imajlar, distorsiyonlar ve magnifikasyonların bulunması ve bu magnifikasyonların görüntü genelinde eşit olmaması sebebiyle doğrusal ölçümleri güvenilir olmaması gibi dezavantajlara sahiptir.⁸⁶

2.7.3 Mikro- Bilgisayarlı Tomografi (Mikro- BT)

Uzaysal çözünürlüğün artırılması hedefiyle kesit kalınlığı mikrometre (μm) cinsinden ifade edilen mikro bilgisayarlı tomografiler geliştirilmiştir. Mikro-BT, uzaysal çözünürlüğü 10 μm ile 100 μm arasında olan ayrıntılı görüntüleme

yapılmasına yarayan ileri teknoloji sistemleridir.⁸⁷ Mikro-BT cihazları çalışma prensibi olarak bilgisayarlı tomografilere benzemektedir. Örneklerin üç boyutlu rekonstrüksiyonlarını oluşturmak için, mikrofokal x-ışını kaynağı ve yüksek çözünürlüklü dedektörler kullanılmaktadır.⁸⁸ Mikro-BT dişlerin mine, dentin, pulpa dokusunu ve kök morfolojisini ayrıntılı bir şekilde göstermektedir.⁸⁹ Ancak mikro-BT'nin günlük klinik dental uygulamalar için kullanımı henüz söz konusu değildir, daha çok üç boyutlu dental araştırmalarda referans standart olarak kullanılmaktadır.⁹⁰ Son zamanlarda Someda, Vandevoort, Aboshi gibi araştırmacılar mikro-BT cihazlarının yaş tayini amaçlı kullanımı ile ilgili çalışmalar gerçekleştirmiştir.⁸⁰⁻⁸²

2.7.4 Konik Işınlı Bilgisayarlı Tomografi (KIBT)

KIBT başlangıçta tıp alanında anjiyografi için kullanıma sunulmuştur. Medikal cihaz teknolojilerinin gelişmesiyle birlikte maksillofasiyal bölgenin görüntülenmesi için de kullanılmaya başlayan KIBT, teknolojinin gelişmesi ve maliyetlerin düşmesiyle 1990'lı yılların sonlarında dental kliniklerde de rutin olarak kullanılmaya başlanmıştır.⁹¹

KIBT, çekim tekniği olarak iki boyutlu bir dedektör üzerine üç boyutlu konik şekilli x-ışını demetinin yönlendirilmesi esasına dayanan bir yöntemdir. Çekim sırasında hastanın başı sabittir. Hasta başının etrafında eş zamanlı olarak dönen x-ışın kaynağı ve alan dedektörü ile 360 derecelik tarama yapılmaktadır.⁸⁵

Medikal bilgisayarlı tomografiye göre maliyetinin düşük olması, maksillofasiyal bölgeden ince kesitler alınıp ayrıntılı değerlendirme imkanı sunması, süperpozisyonların olmaması, görüntüyü oluşturan voksellerin izotropik olması nedeniyle üç boyutta da yapılan ölçümlerin doğru sonuç vermesi, hasta dozunun medikal bilgisayarlı tomografiye göre düşük ve işlem süresinin kısa olması gibi avantajları bulunmaktadır. Dedektör boyutunun küçük olması nedeniyle görüntüleme alanının sınırlı olması, Hounsfield ünitesinin değerlendirilememesi, yumuşak doku kontrastının düşük olması yöntemin dezavantajları arasındadır.⁸⁵

2.8 Zeka ve Yapay Zeka

Zeka kavramı, Douglas Lenat ve Edward Feigenbaum tarafından "Karmaşık bir problemi çözmek için gerekli bilgileri toplayıp birleştirme ve kullanabilme

kabiliyetidir.” veya “Karmaşık bir problemi, çözüm arama alanını daraltarak kısa yoldan çözebilme yetisidir” sözleriyle açıklanmıştır. Zeka, genel itibariyle düşünme kabiliyeti, fikir yürütme, kavrama becerisi, nesnel gerçekliği algılama, yargı sahibi olma, durumlardan sonuçlar edinme yetilerinin bütünü olarak tanımlanabilmektedir.⁹²

Zeka üzerine yapılan tanımların genel bir değerlendirilmesi yapıldığında, zeka bilginin beyin tarafından doğru ve hızlı bir biçimde alınıp, değerlendirilmesi olarak da görülebilir.⁸ Bu yeti ve becerilerin dışında soyut düşünme, tecrübe edip öğrenme ve yeni durumlara adaptasyon gibi yetenekler de zeka kapsamında değerlendirilebilmektedir. Canlı olmayan organizasyonların bu tip özellikler ve yeteneklere sahip olması durumu yapay zeka olarak nitelendirilir.⁹²

Yapay zeka bilimsel bir zeminde ele alındığında ise bilgisayar veya bilgisayar destekli bir makinenin insan beyniyle benzer bir biçimde probleme dayalı çözüm üretme, kavrama, durumları değerlendirme ve durumlardan anlam çıkarma, tecrübeye dayalı öğrenme gibi yüksek mantık gerektiren süreçleri gerçekleştirme becerisi olarak tanımlanabilir.⁹³

2.8.1 Yapay Zekanın Tarihsel Gelişimi

“Tarihte üç büyük olay vardır. Bunlardan ilki kainatın oluşumudur. İkincisi yaşamın başlangıcının olmasıdır. Üçüncüsü de yapay zekanın ortaya çıkışıdır.” Massachusetts Teknoloji Enstitüsü Bilgisayar Bilimleri laboratuvar yöneticilerinden olan Edward Fredkin BBC'ye verdiği röportajda bu ifadeleri kullanmıştır.⁸

Yapay zeka alanında gerçekleştirilen ilk çalışmalar 1940'lı yıllarda ortaya konmuştur. 1943'te McCulloch ve Pitts, beynin devre modelini geliştirmişlerdir. McCulloch ve Pitts 1943 yılında insan beyninde bulunan nöronları matematiksel olarak modellemişlerdir. Bu çalışma insan beynine ait devre modeline dair gerçekleştirilmiş ilk çalışma olma özelliği taşımaktadır.⁸

1950 yılında ise Alan Turing, Mind isimli felsefe dergisinde Computing Machinery and Intelligence adlı bir makale yayınlamıştır. Bu çalışma yapay zekayı felsefi anlamda ele alan ilk makale olup ve yapay zeka felsefesi alanında öncü nitelik taşımaktadır. Alan Turing, makalesinde “Makineler düşünebilir mi?” sorusunu

gündeme getirmiş ve felsefi bir tartışmaya yol açmış olup, makinelerin düşünemeyeceği iddiasını savunan fikirleri reddetmiştir.⁸

Modern yapay zekanın izleri, klasik filozofların insanlara ait düşünce sistematüğini simgesel bir sistem olarak tanımlama girişiminde görülebilir. Geleneksel felsefecilerin insanların düşünce yapısını ve sistematüğünü ele alma ve tanımlama girişimleri modern yapay zekaya dair izler taşımaktadır. Ancak yapay zekanın resmi ve bilimsel nitelik kazanması 1956 yılına denk gelmektedir.⁹³

1956 yılında Hanover, New Hampshire, Dartmouth College bünyesinde düzenlenen ve daha sonraları Dartmouth Konferansı olarak anılacak konferans, yapay zekanın tartışıldığı ilk bilimsel toplantı niteliği taşımaktadır.⁸

1950'li yıllarda Samuel'in kodunu yazdığı kontrol edici program, Herbert Simon ve Allen Newell'in geliştirdiği mantık yaklaşımları ve Gelernter'in tasarladığı geometri motoru gibi sistemler, yapay zeka programlarının ilk örneklerini oluşturmaktadır.⁸

1952 ile 1969 yılları arasında ise IBM firması yürüttüğü proje kapsamında satranç oyununu oynayabilen bilgisayar sistemi geliştirmiştir.⁸

Robinson, 1965 yılında yetkin mantıksal yargılarda bulunabilen bir algoritma sistemi ortaya koymuştur.⁸

Yapay zeka, bu öncül nitelikler taşıyan çalışmalarla birlikte 1970'li yıllara değin hızla gelişim göstermeye devam etmiştir ve dönemin önemli bilim insanları yapay zekanın hızla gelişeceği yönünde açıklamalarda bulunmuştur. Yapay zekanın gelişimi ve bu gelişimin hızı 1974 ile 1980 yılları arasında hararetli tartışmaların odağı haline gelmiştir. Bu dönemde yapay zeka, eleştiri temelli olumsuz raporların hedefi haline gelmiştir. Bu nedenden ötürü bu yıllarda yeterli destek ve yatırım bulunamaması sebebiyle gelişim hızında bir gerileme yaşanmıştır. İlerleyen dönemlerde, bu dönem yapay zeka kışı olarak anılmıştır.⁹³

1980'li yıllarda ise, devletlerin teknoloji alanında birbirleriyle olan rekabeti sonucu yapay zeka alanına kaynak ve destek sağlanmıştır. Bunun sonucunda kayda

değer ilerlemeler yeniden görülmeye başlanmış olup ise yapay zeka, sektörel yapı kazanacak bir konuma yükselmiştir.⁸

1997 yılına gelindiğinde, yapay zeka teknolojisi ile geliştirilmiş bir satranç oyunu olan Deep Blue, dünya satranç şampiyonu Kasparov'u mağlup etmiştir.⁸

2000'li yıllarda yapay zeka teknolojisi birçok alanda gelişme göstermeye devam etmiştir. Bu dönemde, özellikle robotik alanında, iletişim ve haberleşme sistemlerinde yapay zeka teknik ve teknolojilerinin örneklerine sıkça rastlanmıştır.⁸

2.8.2 Güçlü Yapay Zeka, Zayıf Yapay Zeka Kavramları ve Düşünce Deneyleri

Zayıf yapay zeka kavramı, makinelerin bir takım sınırlı insansı zeki davranışlarda bulunabilmesi anlamına gelmektedir. Güçlü yapay zeka kavramı ise, makinelerin programlanmasıyla daha gelişmiş davranışlar sergileyerek, bilinç kazanabilmesi ile açıklanmaktadır.⁹³

Yapay zekanın temel prensibi öğrenme yetisi ile ilişkilendirilmektedir. Örneğin bir insanın bir problemin üstesinden gelmek ve bir işi gerçekleştirme becerisi kazanması için eğitim sürecinden geçmesi gerektiği gibi yapay zekanın da kendisine sunulan problemi çözüme kavuşturabilmesi için eğitim sürecinden geçmesi gerekmektedir. Yapay zekanın en büyük avantajlarından biri, bir problem üzerine eğitimden geçtikten sonra öğrendiği çözüm yolunu çok hızlı bir biçimde uygulayabilmesidir. Bu durum çok büyük boyutlu verilere sahip problemlerin çözümünde önemli faydalar sağlamaktadır.⁹³

Yapay zekanın işleyişini anlamak üzerine bilim insanları tarafından bir takım düşünsel deneyler tasarlanmıştır. Turing Testi ve Çince Odası Deneyi öne çıkan iki deneydir.

Turing Testi

Alan Turing'in geliştirdiği ve onun ismiyle anılan Turing Testi, bir bilgisayarın veya bir makine sisteminin insanlar ile benzer bir bilişsel yeteneğe sahip olup olamayacağını test etmeyi hedefleyen bir test mekanizmasıdır. Bu testte bir bilgisayar

sistemi ve bir insan denek olarak kullanılır. Hangi deneğin insan olduğu, hangi deneğin ise bilgisayar sistemi olduğu uzmandan gizlenir. Deneyi yapan uzman, bu iki denekle haberleşir ve deneklere sorular sorar. Bu sorular ve deneklerin cevapları bir ekrana yansıtılır. Deneyi yapan uzman, yaptığı sorgulama sonucu muhatabının insan mı bilgisayar mı olduğunu net bir biçimde ayırtamaz ise bilgisayar sistemi Turing Testi'nde başarılı kabul edilir ve o sistemin bir insan kadar algılama becerisine sahip olduğu varsayılır.⁸

Çince Odası Deneyi

California Üniversitesinde görevli çağdaş zihin felsefecisi John Rogers Searle, Alan Turing'in görüşlerine bir antitez olarak Çince Odası Deneyi adıyla anılan düşünce deneyini tasarlamıştır. Çince Odası Deneyi, yalnızca İngilizce bilen bir bireyin tek başına kilitli bir odada olduğu varsayımıyla başlamaktadır. Bu birey, üzerinde Çince sembollerin bulunduğu bir kart dizisine ve bu sembollerin ne anlama geldiğinin İngilizce olarak açıklandığı bir kurallar kitabına sahiptir. Odadaki birey, bir kapıdan içeri verilen ve üzerinde Çince sorular yazılı olan bir kartı alıp diğer kapıdan bu sorulara kurallar kitabı yardımıyla Çince olarak cevap verilmiş olan başka bir kartı dışarı vermektedir. Bireyin dışarı verdiği kağıtlar Çinceyi ana dili olarak konuşan birinin ayırt edemeyeceği kusursuzluktadır. Ancak kartlarda bulunan Çince sembollerin odadaki birey tarafından tanınması yalnızca biçimsel olarak sınırlıdır ve yazıların içeriği birey tarafından kesinlikle anlaşılmamıştır. Odadaki birey, aslen ne olduğunu hiçbir şekilde bilmediği verileri, kuralları takip ederek manipüle etmiştir ve bu manipülasyonu herhangi bir farkındalık geliştirmeden gerçekleştirmiştir.^{8,94}

Çince Odası Deneyi'nin özü özetle şu şekilde ifade edilebilir. Aslında Çince tek bir sözcüğü dahi anlayamayan birey, odanın dışında bulunan gözlemcinin bakış açısına göre sanki Çince anlıyor gibi algılanmaktadır. Bu deneydeki birey, yapay zeka sistemlerini temsil etmektedir ve bu sistemler Turing Testi'ni geçeceklerdir. Dolayısıyla Searle'ye göre sadece sembollerle yapılan hiçbir işlem, anlam garantisi vermemektedir. Searle, Turing Testi'ni geçen bir makinenin insan kadar algılama becerisine sahip olduğu varsayımının aksine, yapay zekanın insan kadar bilinçli sayılabilmesi için daha farklı özelliklere sahip olması gerektiğini savunmaktadır ve zeka sahibi olmanın yalnızca bilinç sahibi olan varlıklara özgü bir nitelik olduğunu

savunmaktadır. Searle bu düşünce deneyi ile güçlü yapay zeka kavramına karşı yönde bir duruş göstermiştir.⁸

2.9 Yapay Zeka Algoritmaları

Yapay zeka algoritmaları uzman sistemler, bulanık mantık, genetik algoritmalar, yapay sinir ağları, makine öğrenmesi gibi başlıklar altında incelenmekte ve sınıflandırılmaktadır.⁸

2.9.1 Uzman Sistemler

Uzman sistemler, belirli bir alandaki bir uzmanın veriye dayalı problemlerin çözümündeki becerisini taklit etmek üzere geliştirilmiş, yüksek organizasyon gösteren bilgisayar yazılımlarıdır.⁹⁵ Uzman sistemlerin yapay zekadan ayrışan noktası ise yapay zeka, insanların çözebileceği problemi çözmeye yönelik çalışırken, uzman sistemler belirli bir konuda uzman olan kişilerin çözdüğü problemleri çözmeyi hedeflemesi olarak gösterilmektedir. Uzman sistemler ile uzman kişilerin yerinin alınması hedeflenmemektedir. Bu sistemler, gerçek hayatta uzman kişilere erişimin sınırlı olduğu alanlarda problem çözümüne katkıda bulunmaktadır. İlk geliştirilen uzman sistem, 1970 yılında Stanford Üniversitesindeki hekimler tarafından bakteriyel kaynaklı menenjitin teşhis ve tedavisine fayda sağlanmasına yönelik bir sistem olarak tasarlanmıştır.⁸

2.9.2 Bulanık Mantık

Bulanık mantık, ilk defa Berkeley Üniversitesinde Prof. Dr. Lotfi Aliasker Zadeh'in makalelerini yayınlamasıyla bilim dünyasında kendine yer bulmuştur. Bulanık mantık, ikili mantıkta doğru ya da yanlış, 0 ya da 1 şeklinde tanımlanan değerlendirmelerin dışında ara değerler içeren uygulamaları tanımlamakta kullanılmaktadır. Bulanık mantık gündelik hayatta olduğu gibi doğrudan ikili şekilde değerlendirilemeyecek durumların tanımlanmasında uygun düşmektedir. Girdi ile çıktı arasında net bir sonuç olmadığı durumlarda, yani siyah ya da beyaz olarak bir tanımlamanın mümkün olmadığı sistemlerde gri alanların ifadesi bulanık mantığın çalışma prensibini açıklamaktadır.⁸

2.9.3 Genetik Algoritmalar

Genetik algoritmalar, canlı organizma sistemlerine benzer bir öğrenme sürecine sahip yazılım sistemleri olarak karşımıza çıkmaktadır.⁸ Genetik algoritmalar, ilgili problemlerin çözümünde canlı organizmalara benzer bir şekilde, doğal seçilim gibi kalıtıma dair nitelikleri baz alan bir matematiksel model olarak açıklanmaktadır.⁹⁶ Bu algoritma, canlı organizmalardaki mutasyon ve çaprazlama kavramlarına karşılık gelen iki temel fonksiyon içermektedir. Genetik algoritmaların kullanıldığı problem aralığı geniş yelpazede ele alınmaktadır. Genel olarak, fonksiyonların optimizasyonunda başarılı sonuçlar vermektedir.⁹⁷

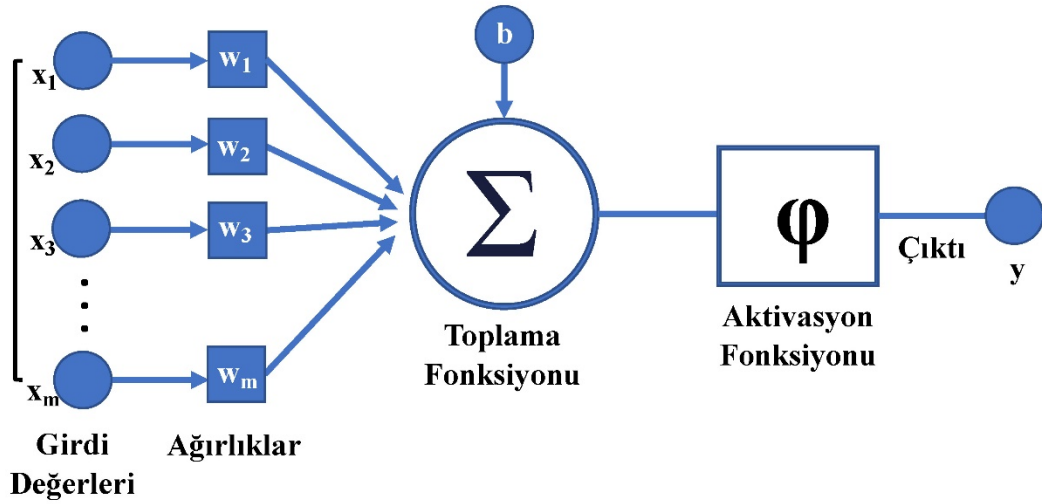
2.9.4 Yapay Sinir Ağları

Yapay sinir ağları, insana beynine ait özelliklerden fikir yürütme, öğrenebilme, öğrenilen bilgiler üzerinden çıkarımlarda bulunma ve yeni bilgiler türetme gibi becerileri, insan beynindeki nöronların yaptığına benzer bir biçimde otomatik olarak gerçekleştirme hedefiyle geliştirilmiş bilgisayar program sistemleri olarak özetlenebilir.⁹⁸

Yapay sinir ağları, klasik programlama yöntemleriyle çözüme ulaşması çok zorlayıcı, çözüm için çok uzun zaman gerektiren ve hatta çözümü olasılık dışı olan problemler için tasarlanmış adaptif bilgi işleme üzerine tanımlanan bir bilgisayar alanı olarak da nitelendirilebilir. Gerçek bireyler tarafından gerçekleştirilmiş örnekler üzerinden öğrenme becerisi geliştiren bu sistemler, öğrenilmiş bilgilere karşın tepkiler üretebilmektedir.⁹⁸

Yapay sinir ağları, ilgili sisteme sunulan yapılar arasında hiyerarşik olarak bağlantılı ve bununla birlikte eş zamanlı çalışabilen yapay olarak oluşturulmuş hücreler bütünüdür. Fonksiyon elemanları olarak da tanımlanabilecek bu yapay hücrelerin birbirleri ile ilintili olup her birinin kendi içinde bir değeri olduğu kabul edilmektedir. Bu sistemler, insan beynine ait yapısal niteliklere benzer biçimde; öğrenme, olaylar ve durumlar arasında ilişki kurabilme, gruplandırma, öznitelik çıkarma, genelleme ve optimize etme gibi alanlarda başarılı sonuçlar vermektedir. Yapay sinir ağları, bu yönüyle güncel birçok soruna çözüm üretme potansiyeline sahiptir.⁹⁸

Yapay sinir ağlarının temel fonksiyon elemanına yapay sinir ağı hücresi adı verilir. Şekil 2.1'de temel bir yapay sinir ağı hücresi modeli yer almaktadır. Şekilde gösterilen modellemede x sembolleri giriş sinyallerini, w sembolleri gerçek bir nörona benzer biçimde sinaptik ağırlıkları temsil etmektedir. Toplama kısmında ağırlıklı giriş sinyalleri yer alır. Sembol ϕ , aktivasyon fonksiyonunu temsil etmektedir ve yapay sinir hücresinin çıkış büyüklüğünün sınırlandırılmasında görev almaktadır. Sembol b (bias), sabit değeri bulunan bir elemandır ve aktivasyon fonksiyonunun net girişinde artım ya da azaltım işlevi görmektedir.⁹⁹



Şekil 2.1 Yapay sinir ağı hücresi modeli

Bir yapay sinir ağı hücresinin çalışma mekanizmasını anlayabilmek için aktivasyon fonksiyonu ve buna bağlı giriş-çıkış sinyallerinin ağırlıklı bağlantılarının yapısını incelemek gereklidir. Yapay sinir ağı hücrelerinin katmanlar üzerinden tanımlanan yapısında, katmanların her birini oluşturan yapay sinir ağı hücresinde çoğunlukla aynı aktivasyon fonksiyonu ve bağlantı kurgusu görülür. Daha yalın bir ifadeyle ele almak gerekirse, birçok yapay sinir ağı sisteminde, sistemi oluşturan bir katmandaki yapay sinir ağı hücreleri ya bütünüyle birbirine bağlı ya da bütünüyle ayrık yapı göstermektedir. Bir katmanın içindeki herhangi bir yapay sinir ağı hücresi (örn. saklı birimdeki katman) başka bir katmandaki (örn. çıkış katmanı) bağıllık gösteriyorsa, yapay sinir ağını oluşturan tüm saklı katmandaki hücreler çıkış katmanındaki tüm hücreler ile bağlantılıdır.⁹⁹

Yapay sinir ağlarıyla ilgili önemli bir terim de ağ mimarisidir. Yapay sinir ağı hücrelerinin sistemi oluşturan katmanlar içerisine diziliş düzeni, katmanların kendi

içlerinde ve aralarındaki bağlantı yerleri ağ mimarisi kavramını oluşturmaktadır. Birçok yapay sinir ağı sisteminde, aktivasyon fonksiyonuyla giriş sinyallerinin eşit olduğu giriş katmanı bulunmaktadır. Yapay sinir ağları sistemleri tekli katman içeren ve çoklu katman içeren sistemler olarak sınıflandırılabilir. Sistemlerin katman sayısı hesaplanırken, giriş birimleri hesaba katılmamaktadır.⁹⁹

Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları sistemleri, giriş katmanı, ara katman (gizli katman) ve çıkış katmanı olmak üzere üç temel katmandan oluşmaktadır. Giriş katmanı, dış dünyadan gelen bilgileri sisteme entegre etmektedir. Bu katmanda herhangi bir bilgiyi işleme süreci gerçekleştirilmemektedir. Giriş katmanından elde edilen bilgiler, sonraki katmanlardaki tüm fonksiyon elemanlarına yollanmaktadır. Gizli katman adı da verilen ara katmanlar, giriş katmanından gelen bilgileri işlemektedirler. Yapay sinir ağları sistemlerinde problemlerin çözümünü gerçekleştirmek için genellikle bir tane ara katman yeterli olmaktadır. Yapay sinir ağının öğrenmesi hedeflenen problemin girdisi ile çıktısı arasındaki bağlantı lineer olmaz ise ve problemdeki karmaşıklık düzeyi artarsa daha fazla sayıda ara (giriş) katman kullanılabilir. Çıkış katmanı ise, ara (giriş) katmandan gelen bilgileri işler ve giriş katmanından girişi sağlanan çıktıyı bulmakla görevli katmandır.⁹⁹ Çok katmanlı yapay sinir ağlarının eğitim sürecinde sistemin elde ettiği çıktılar ile hedeflenen çıktılar arasındaki farkların veya hataların ağıdaki katmanların ağırlıklarına bağlı olarak dağıtılarak eğitim süreci boyunca bu farkın zamanla minimize edilmesi hedeflenmektedir.¹⁰⁰ Yapay sinir ağları ileri beslemeli ve geri beslemeli olarak ikiye ayrılmaktadır;

I. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağları, giriş katmanından elde edilen verileri, ağırlıklarını göz önünde bulundurarak işleyen ve doğrudan çıkış katmanına aktaran bir sistem olarak tanımlanır. Bu sistemlerden, geri beslemeli yapay sinir ağlarıyla ele alınan problemlere göre daha basit problemlerin çözümünde yararlanılmaktadır. İleri beslemeli yapay sinir ağ sistemleri, tek katmanlı ya da çok katmanlı olabilmektedir. Eğitim süreci boyunca girdiler öncelikle yapay sinir ağına sunulur ve bu girdilere karşılık çıktılar elde edilir. Bu işlemler bütünü ileriye doğru hesaplama terimiyle ifade edilir.¹⁰⁰

II. Geri Beslemeli Yapay Sinir Ağları

1970'lerin başında geliştirilen geri beslemeli yapay sinir ağı sistemleri, tanımlanmamış karmaşık problemlere karşılık, etkili, doğrusal olmayan çözümler bulabilen bir yapay sinir ağı sistemidir. Tipik bir geri beslemeli yapay sinir ağında, bir giriş, bir çıkış ve en az bir ara (gizli) katman bulunmaktadır. Geri beslemeli yapay sinir ağlarında katman sayıları ve her katmanda bulunan düğüm sayısı belirli kurallar takip edilerek seçilmelidir. Bu kurallar aşağıdaki gibidir:

- Probleme ait girdiyle çıktı arasındaki bağlantının karmaşıklık seviyesi yükseldikçe, ara (gizli) katmanlardaki fonksiyon elemanlarının sayısı da aynı oranda yükseltilmelidir.
- Probleme ait süreç aşamalara parçalanabilir durumda ise uygun ara (gizli) katmanlar oluşturulmalıdır. Eğer problem süreci aşamalara parçalanamayıp gereksiz ara (gizli) katman oluşturulursa yapay sinir ağında ezberleme gelişir ve problemin çözümünde yanlış sorunlara varılabilir.
- Yapay sinir ağının eğitim sürecinde kullanılan eğitim veri setinin miktarı, ara (gizli) katmanlardaki fonksiyon elemanlarının sayısında üst sınır belirlenmelidir.
- Ağda kullanılan eğitim verisinin miktarı ile gizli katmanlardaki işleme elemanlarının sayısı için bir üst sınır oluşturulmalıdır.
- Ara (gizli) katmanların mümkün olduğunca az miktarda fonksiyon elemanı içermesine dikkat edilmelidir. Belirtilen bu kurallar çerçevesinde yapay sinir ağı sisteminin eğitim sürecine geçilir. Sistemin öğrenim süreci sırasında, sistemi oluşturan ağda ileri doğru tarama yapılmakta ve her düğümden gelen çıktı verisi katman katman hesaplanmaktadır.⁹⁸

Geri beslemeli yapay sinir ağı sistemlerindeki yapı, doğrusal yapı göstermemektedir. Sistem, gizli katmanlar ve giriş-çıkış katmanlarının arasında birbirlerine dönüş yapılabilecek bir biçimde çoklu bağlantı kurma sistematığına dayanmaktadır. Geri beslemeli yapay sinir ağı sistemleri bu tarz çoklu bağlantı kurabilme avantajı nedeniyle karmaşık, çözümü güç problemlerin ve denklemlerin çözümünde başvurulan bir yöntem olarak karşımıza çıkmaktadır.⁹⁸

2.9.5 Makine Öğrenmesi

Yapay zekanın alt dallarından olan makine öğrenmesi, sisteme sunulan veri setinden kendi kendine öğrenebilen, programlama yapılmadan tahminlerde bulunabilen, karar verme yetisi geliştiren ve sistemin eğitiminde örnek olarak gösterilen veriler üzerinden matematiksel bir modelleme oluşturabilen algoritmalar bütünü olarak tanımlanabilir. Makine öğrenmesine sahip uygulamalar, sistemdeki veriler üzerinden öğrenme gerçekleştirebilir, tahminlerde ve problemin çözümü için önerilerde bulunabilir. Bu durum, bilgisayar programlarının performanslarında iyileştirmeler sağlamaktadır.^{101,102}

Yapay zeka algoritmalarının yapay sinir ağları, makine öğrenmesi gibi alt dallarında, sistemde bir eğitim seti ve bir test seti bulunmaktadır. Eğitim seti, etiketli verilerin olduğu kümenin ve makine öğrenmesinin kullanabileceği etiketlenmemiş verilerden oluşan örnek kümedir. Test seti ise, sistem tarafından daha önce görülmemiş verilerden oluşan kümedir. Makine öğrenmesi, eğitim kümesi üzerinden öğrenme becerisi geliştirerek bir sistem kurmayı ve takiben test seti ile sistemin performansını değerlendirmeyi hedeflemektedir.¹⁰³

Denetimli Öğrenme, Denetimsiz Öğrenme, Destekleyici Öğrenme ve Hibrit Öğrenme Kavramları

Makine öğrenmesi sistemlerinde, sunulan verilerden anlamlı ilişkiler çıkarmak amacıyla denetimli öğrenme, denetimsiz öğrenme, destekleyici öğrenme ve hibrit öğrenme gibi yöntemler kullanılmaktadır.¹⁰⁴

Denetimli öğrenme modeline sahip sistemlerde, sisteme giriş verisiyle beraber problemin çözümünde beklenen çıkış verisi de sunulmaktadır. Modelin çalıştırılmasıyla birlikte elde edilen çıkış verilerinin beklenen değerde olup olmaması kıyaslanmaktadır.¹⁰⁴ Denetimli öğrenme modelinde, sisteme sunulan veriler tanımları belirgin olarak yapılmış sınıflar arasında dağıtılmaya çalışılır. Ardından sisteme sunulan yeni verilerin hangi gruba ait olduğu tahmin edilmeye çalışılır.¹⁰⁵

Denetimsiz öğrenme sistemlerinde, yalnızca çözülmesi hedeflenen probleme yönelik giriş verileri sisteme sunulmaktadır. Sistem, giriş verisinin niteliğine bağlı olarak öğrenme fonksiyonunu kendi kendine gerçekleştirmektedir. Sınıflar belirsiz

olduğu için, sistemde öncelikle verilerin analizi yapılarak belli sınıflar oluşturulmaya çabalanır. Ardından sisteme yeni entegre edilen verilerin hangi sınıfa dahil olduğu tahmin edilmeye çalışılır.^{104,105}

Destekleyici öğrenme sistemlerinde hem denetimsiz hem de denetimli öğrenme sistemlerine benzer özellikler bulunmaktadır. Sisteme, denetimsiz öğrenme algoritmalarına benzer şekilde sadece probleme dair giriş verileri verilmektedir. Ancak bu sistemde, bir danışman tarafından çıkış verilerinin yanlış mı yoksa doğru mu olduğu gösterilmektedir.¹⁰⁶ Bu yapay zeka modelinde, çevre ile girilen etkileşim aracılığıyla performansın artırılması hedeflenmektedir. Destekleyici öğrenme sistemlerinin kullanıldığı uygulamalara yaygın bir örnek olarak satranç oyunu gösterilebilir.¹⁰⁷ Destekleyici öğrenme sistemleri robotik alanındaki araştırmalarda da yaygın biçimde kullanılmaktadır.¹⁰⁸

Hibrit öğrenme sistemlerinde ise hem denetimli hem de denetimsiz öğrenme teknikleri bir arada kullanılmaktadır. Bu sistemlerin asıl hedefi sınıflandırma yapmaktır. Yapılan güncel çalışmalarda genellikle denetimsiz öğrenme algoritmaları, denetimli öğrenme algoritmalarına yardımcı nitelikte uygulanmaktadır.¹⁰⁹

Karar Ağaçları

Denetimli öğrenme modeli sınıfına ait bir algoritma olan karar ağaçları, yapay zeka uygulamaları alanında ilk geliştirilen algoritmalarından biridir. Uygulaması basit bir tekniktir. Ancak problemlerin çözümünde oldukça güçlü, etkili bir analiz sunmaktadır. Karar ağacı algoritmaları, tekrarlanan sınıflandırma olarak da isimlendirilmektedir. Bu yapay zeka modeli, sisteme sunulan birkaç farklı giriş değişkeni üzerinden öngöründe bulunan algoritmalar geliştirilmesinde kullanılmaktadır.^{110,111}

Karar ağacı modelleri yapısal olarak bir ağacın yapısına benzer şekilde, dallar, yapraklar ve düğümlerden oluşmaktadır. Modeli oluşturan düğümlerin sıralamaları, öznitelik çıkarımı olarak adlandırılan ve doğruluğun çok önemli olduğu matematiksel işlemler kullanarak gerçekleştirilmektedir. Öznitelik çıkarımı için Gini Index ve Information Gain adı verilen ölçütler kullanılmaktadır. Öznitelikteki belirsizlik olgusu entropi olarak tanımlanmaktadır. Özniteliklerin entropileri değerlendirilerek Gini

Index ve Information Gain değerleri hesaplanabilmektedir. Entropi değerindeki azalma, özneliklerin sınıflandırılması üzerinden Information Gain değeriyle hesaplanmaktadır. Öznelik ve ayırım yapmada en başarılı eşik değerler ve en yüksek Information Gain değerine sahip eşik değerler seçilir. Yüksek değere sahip öznelikler modelde kök olarak değerlendirilirken entropi değeri sıfır olan dallar yaprak düğümü olarak ele alınmalıdır. Entropi değeri sıfırdan yüksek olan dalların ise daha fazla ayrıştırılması gerekmektedir. Gini Index değeri rastgele olarak ele alınan bir örneğin sınıflandırılmasında hangi sıklıkla yanlış yapıldığını göstermektedir. Bu sebeple, karar ağacı modellerinde öznelik seçiminde Gini Index değeri düşük değerler seçilmeye dikkat edilmelidir.^{111,112}

Karar ağacı modeline sahip sistemler, genellikle tıp alanında yapılan çalışmalarda tahmin araştırmalarında, sınıflandırma yapma çalışmalarında ve problemleri yorumlama alanında kullanılmaktadır. Bu sistemler, bulgular tanımlanırken, asıl verideki giriş değişkenlerinin gruplara bölünerek, hedeflenen değişkenlerle arasındaki ilişkilerdeki karmaşıklığın basitleştirmesi, problemin anlaşılması ve yorumlanmasının basitleştirilmesi gibi avantajlara sahiptir.¹¹³

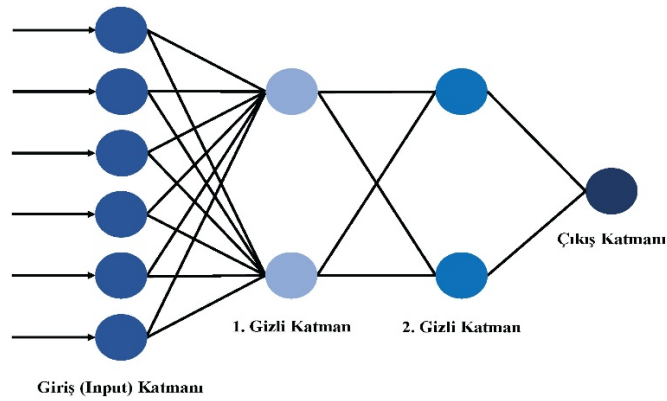
Karar ağacı modellerinin eğitim süreci parametrik değildir. Dolayısıyla modeller ihtiyaç duyulduğunda büyütülebilmektedir. Karar ağacının büyüklüğü, çözümü hedeflenen problemin karmaşıklık seviyesine bağlı olarak değişmektedir. Basit problemlerde sistemin tanımladığı ağaç küçük iken problem zorlaştıkça karar ağacı büyümektedir.¹¹⁰

2.10 Derin Öğrenme

Uzun bir süre boyunca, yapay zeka algoritmalarında sığ yapılanma gösteren mimariler kullanılmıştır. Sığ yapılanmalı mimariler, çoğunlukla lineer olmayan dönüşümler içeren, en çok iki katmanlı sistemler olarak karşımıza çıkmaktadır. Bu sığ yapılmış mimarilere örnek olarak lojistik regresyon sistemleri, maksimum entropi modelleri, lineer olmayan dinamik sistemleri örnek olarak verilebilir. Pek çok problemin üstesinden gelmede başarılı sonuçlar veren bu mimariler, daha karmaşık sinyaller içeren verilerdeki problemleri çözmede yetersiz kalmaktadır. Veri setlerindeki karmaşıklığın artması ve veri setinin büyüklüğünün artması nedeniyle yapay sinir ağlarının öğrenme becerisinin artırılmasına yönelik pek çok yeni

yaklaşımında bulunulmuştur. Bu amaçla geliştirilen yaklaşımlardan biri de derin öğrenme algoritmalarıdır. Derin öğrenme algoritmaları ile karmaşık veri setlerine sahip problemlerde verilerin işleme süreci ve problemleri anlamlandırma açısından kolaylık sağlanmıştır. Derin öğrenme sistemleri, yapay sinir ağları yapısından esinlenilmiş algoritmaların kullanımına dayanan, makine öğrenmesi sistemlerinin bir alt kolu olarak tanımlanabilmektedir.^{101,109}

Çok katmanlı yapay sinir ağlarının tanımlı veriler üzerinden gruplandırılması, derin öğrenmenin temel yapısını oluşturmaktadır. Karmaşık verilerden oluşan problemlerin (örn. insanlara ait seslerin bilgisayarlar tarafından ayrımı, veri setlerini oluşturan görsellerdeki piksellerin nesnelere eşleşmesi) klasik yapay zeka algoritmaları ile çözümü oldukça zordur. Bu noktada, derin öğrenme sistemlerinin karmaşık problemleri, veri setini hiyerarşik bir biçimde sınıflandırması sayesinde problemin çözümü basitleştirilmektedir. Tipik bir derin öğrenme sistemi, problemin veri setini oluşturan yapıları temsil eden bir giriş katmanından, çok sayıda saklı katmandan ve çıkış katmanından oluşmaktadır. Saklı katman kavramı, veri setindeki ilişkilerin sistem tarafından anlaşılmasına yarayan bağlantılar içermektedir.^{110,114} Şekil 2.2'de tipik bir derin öğrenme yapısı modellenmiştir.



Şekil 2.2 Derin Öğrenme yapısı

2.10.1 Derin Konvolüsyonel Sinir Ağları (Deep-CNN)

Derin öğrenme sistemlerinin birçoğu, sistemi oluşturan sinir ağının bağlantılarını kendiliğinden saptamaya ve kısıtlamaya yarayan konvolüsyon (evrişim) olarak adlandırılan bir yöntemden yararlanmaktadır.¹¹⁵

Derin öğrenme sistemlerinin esas mimarisini konvolüsyonel sinir ağları oluşturmaktadır. Konvolüsyonel sinir ağlarında, sisteme ardışık olarak yerleştirilmiş birçok eğitilebilir katman bulunmaktadır. Giriş verileri sisteme sunulduktan sonra, eğitim süreci katmanlar boyunca tek tek gerçekleştirilir. Doğru sonuç ile karşılaştırma yapılarak çıkış verisi elde edilir. Hata, istenen sonuç ile sistemin ürettiği sonucun farkı kadardır. Konvolüsyonel sinir ağlarında yapılan hata sistemin tüm ağırlıklarına aktarılmakta ve bu aktarımda geri yayılım algoritması kullanılmaktadır.¹¹⁶

Konvolüsyonel sinir ağlarında her bir birim kendinden önceki birimlere ait küçük bir alt kümeyle beslenmektedir. Sonraki birimlerin ise küçük bir alt kümesini beslemektedir. Bu sayede sistemdeki karışma miktarı daha az olmakta ve sistemin eğitimi daha hızlı gerçekleştirilmektedir.¹¹⁰

2.10.2 Derin Öğrenmenin Katmanları

Giriş (Input) Katmanı

Giriş katmanı, verilerin sisteme girişinin yapıldığı katmandır. Giriş katmanında veriler sisteme ham veri olarak sunulmaktadır. Sisteme sunulan veri setinin yapay zeka ağ mimarisine uygunluğu önceden belirlenmelidir. Sisteme sunulan veriler algoritmanın eğitimi için giriş verisi niteliğindedir. Sistemin başarılı olmasında veri setinin büyüklüğü önemli bir parametredir. Veri setinin büyüklüğü arttıkça, bellek gereksinimi, sistemin eğitimi için gereken süre artmaktadır ancak algoritmanın başarısı da aynı oranda artmaktadır.^{117,118}

Konvolüsyon (Evrışim) Katmanı

Konvolüsyonel sinir ağlarının temelini, evrişim katmanı adı da verilen konvolüsyon katmanı oluşturmaktadır. Konvolüsyon katmanında, probleme özgü olarak tanımlanmış bir filtre, giriş verileri üzerinde gezdirilmektedir. Konvolüsyon işlemi adı verilen bu işlem ile giriş verileri üzerindeki belirgin özniteliklerin keşfedilmesi hedeflenmektedir. Çok katmanlı konvolüsyonel sinir ağlarına ait mimarilerde, filtreleme çok önemli bir işlem olup farklı boyutlarda filtrelerle konvolüsyon işlemi yapılabilmektedir. Bu filtreleme işlemiyle birlikte giriş katmanına sunulan veriler üzerinden aktivasyon haritası oluşturulmaktadır. Filtreleme ile sisteme sunulan giriş verilerinden, daha küçük boyutlu bir matris elde edilmektedir. Seçilen

filtre, konvolüsyonel sinir ağlarının eğitim süresini ve sistemin başarılı olma derecesini birinci dereceden etkilemektedir.¹¹⁹⁻¹²¹

Aktivasyon Katmanı (Rectified Linear Units Layer-ReLu):

Konvolüsyonel sinir ağlarında konvolüsyon katmanının ardından genellikle aktivasyon katmanı gelmektedir. Çok katmanlı konvolüsyonel sinir ağlarında lineer olmayan dönüşümlerden faydalanılmaktadır. Bu katmanda, derin öğrenme ağı, bir önceki katmana ait lineer çıkış verileri bir fonksiyon ile lineer olmayan bir yapıya çevrilmektedir. Aktivasyon katmanının işlevi ile ağın öğrenme hızının artırılması doğrudan ilişkilidir.^{118,119,122}

Havuzlama (Pooling) Katmanı

Aktivasyon katmanından sonra yer alan havuzlama katmanının temel işlevi bir sonraki katmana sunulacak giriş verilerinin boyutunu azaltılmasıdır. Bu işlem ile veriler üzerinde gerçekleştirilen kayıpla, veri miktarındaki azalma sonucu konvolüsyonel sinir ağının hızında artış görülmektedir. Sistemdeki veri miktarının azalması, konvolüsyonel sinir ağı katmanlarındaki hesap yükünde ve sistem için gereksinim duyulan bellek miktarında azalmaya yardımcı olmaktadır. Ayrıca veri yükünün azalması konvolüsyonel sinir ağındaki ezberlemenin önüne geçmekte de faydalı olmaktadır.¹²³

Havuzlama işlemi temel olarak, bu katmana sunulan giriş verisinin boyutlarının derinlik cinsinden sabit tutulurken, yükseklik ve genişlik cinsinden azaltılması işlemidir. Bu işlem yapılırken belirli filtreler veri görüntü matrisi içinde dolaştırılmakta ve seçilen filtreye uygun değerlerin bulunması hedeflenmektedir. Bu değerlerin elde edilmesi sırasında en çok, ortalama havuzlama (average-pooling) ve maksimum havuzlama (max-pooling) işlemleri kullanılmaktadır. Performans açısından daha iyi sonuç vermesi nedeniyle genellikle maksimum havuzlama kullanılmaktadır.^{119,123,124}


Tam Bağlı (Full-Connected) Katman

Tam bağlı katmanda, sistemi oluşturan nöronlar bir dizi şeklinde görünmektedir. Bu katmanı oluşturan nöronlar, önceki katmanların tamamına tam

bağlı olarak bulunmaktadır. Bu katmanın gösterdiği özellikler, kendinden önceki katmanların özelliklerine göre ortaya çıkmaktadır. Tam bağlı katmanda, sistem için oluşturulmuş sınıflar, ilgili sınıflarla yüksek derecede ilişki gösteren özellikler incelenmektedir. Özelliklerin belirtildiği nöronların ağırlıkları hangi sınıfa dahil oldukları bilgisini vermektedir.^{119,125}

Drop Out Katmanı

Konvolüsyonel sinir ağı sistemlerinin eğitim sürecinde, ağda aşırı öğrenme olarak da isimlendirilen sistemin ezberlenmesi gerçekleşmektedir. Ağın ezberlenmesi, yapay sinir ağlarında arzu edilmeyen bir durum olmaktadır. Drop out katmanı, bu durumun üstesinden gelinmesi için ağda ezbere yol açan birtakım düğümlerin sistemden çıkarılmasına yardımcı olmaktadır. Hinton ve ark. tarafından önerilen bu katman modelinin sinir ağlarının düzenlenmesi noktasında katkı sağladığını doğrulayan testler mevcuttur.^{119,126} Drop out katmanında devre dışı bırakılan düğümlere ait bir örnek Şekil 2.4'te sunulmuştur. Çarpıyla işaretlenmiş nöronlar sinir ağından çıkarılmıştır.



Şekil 2.3 Drop out işlemi uygulanmamış ve uygulanmış bir sinir ağı modeli

Sınıflandırma (Classification) Katmanı

Sınıflandırma katmanı, tam bağlı katmandan sonra yer almaktadır. Bu katmanda gerçekleştirilmesi hedeflenen görev, sınıflandırması gereken eleman miktarına eşit sayıda sonuç elemanı üretmektir.¹¹⁸

Yumuşatma (Softmax) Katmanı

Softmax katmanı, bir sınıflandırma katmanıdır. Bu katmana giriş verileri tam bağlı katmandan sunulur. Softmax katmanının temel işlevi sunulan giriş verisinin hangi sınıfa dahil olduğunun ya da olasılıksal olarak hangi sınıfa daha yakın olduğunun belirlenmesidir. Sistem içinde olasılık hesabı yapılmakta ve oluşturulan her bir sınıf için olasılık değeri belirlenmektedir. Bu hesaplar yapılırken çapraz entropi kavramı kullanılmaktadır.¹²⁷

Normalizasyon Katmanı

Derin konvolüsyonel sinir ağlarının eğitimi, sistemin hesap yükünden dolayı oldukça zaman alan bir süreçtir. Eğitim süresinin kısaltılması noktasında izlenebilecek adımlardan biri de sistemi oluşturan nöronların aktivasyonlarının normalizasyonudur. Normalizasyon işlemi genellikle aktivasyon katmanından sonra gerçekleştirilmektedir. Normalizasyon, geri beslemeli konvolüsyonel sinir ağlarına sahip sistemlerde gizli katmanların stabilizasyonunda büyük ölçüde etkili bir işlem olarak sistemin performansını etkileyen bir katman olarak karşımıza çıkmaktadır.¹²⁸ Sistemi oluşturan önceki katmanlardan gelen giriş verileri, çok büyük veya çok küçük değerler içeren verilerden oluşmaktadır. Sistemin işleyişi için veri seti, belli bir değer aralığı içinde düzenli olmalıdır.¹²⁹

2.10.3 Konvolüsyonel Sinir Ağlarının Eğitilmesi

Konvolüsyonel sinir ağlarının eğitiminde konvolüsyon, havuzlama, tam bağlı katman ve sınıflandırma katmanı ile belirlenen temel bir model oluşturulur. Modeldeki katmanların sıralaması ve sayısı modeli oluşturan yazılımcıya bağlı olarak kurgulanmaktadır. Kullanılan filtrenin matris boyutları, filtre sayısı tanımlanır. Giriş verisi olarak eğitim setinden bir veri, oluşturulan modele sunulur. Bu veri, oluşturulan modelin katmanlarından geçirilerek bir sonuç verisi elde edilir. Bu işlem ileri besleme olarak adlandırılmaktadır. Sistemden çıktı verisi olarak alınan sonuçlar ile beklenen sonuçların arasındaki fark belirlenerek sistemin toplam hata değeri bulunur. Ancak toplam hata değerinin sistemdeki tüm ağırlıklara paylaşılması gereklidir. Toplam hata değerinin düşürülmesi amacıyla sisteme geri besleme adı verilen işlem uygulanır.¹¹⁸

2.11 Diş Hekimliğinde ve Ağız, Diş ve Çene Radyolojisi Alanında Yapay Zeka Uygulamaları

Son yıllarda diş hekimliği pratiğinde, yapay zeka algoritmalarına dayanan, bilgisayar destekli sanal asistan görevi yürüten uygulamalar geliştirilmiştir. Bu sanal asistanlar, klinikte yürütülmekte olan işlerde insan gücü kullanımında azalmasına yardımcı olmakta, kendisine verilen görevleri hassas bir şekilde yürütmektedir. Bu görevler arasında, evrak işlerinin yürütülmesi, hastaların kontrollerinin hatırlatılması, sağlık sigortalarıyla ilgili işlemlerin yapılması, hastaların diş hekimliğine dair herhangi bir maddeye karşı mevcut alerjilerinin hekime hatırlatılması gibi görevler bulunmaktadır.¹³⁰

Yapay zeka temelli çalışmaların hızla artması, maksillofasiyal radyoloji alanındaki araştırmalara da ivme kazandırmıştır. Rutin klinik uygulamalarda yaygın olarak kullanılan intraoral ve ekstraoral radyograflar, yapay zeka çalışmaları için oldukça zengin bir kaynak oluşturmaktadır.⁹

Radyoloji pratiğinde radyologlar, radyograflardaki bulguları değerlendirmekte ve yorumlamaktadır. Bu değerlendirme genellikle gözlemci öznelliğinden önemli ölçüde etkilenmektedir. Ayrıca zaman alıcı olabilmektedir. Yapay zeka uygulamaları bu noktada, radyolojik görüntülerdeki karmaşık modelleri ve örüntüleri otomatik olarak tanıma ve kantitatif analiz gerçekleştirme yönünde katkıda bulunmaktadır.¹³¹ Bu sebeple yapay zeka uygulamaları klinisyenlerin tekrarlanabilir radyolojik değerlendirme yapmaları ve daha doğru teşhisler koymaları yönünde yardımcı bir araç olabilir. Ayrıca yapay zeka alanındaki gelişmelerle birlikte, klinik veriler analiz edilerek, prognoz yönünden öngörülebilir, kişiselleştirilmiş bir tedavi planı sunulmasına yardımcı olabileceği öne sürülmektedir.¹³²

Ağız, diş ve çene radyolojisi alanında yapay zeka ile gerçekleştirilmiş çalışmalar incelendiğinde, derin öğrenme tekniklerine dayanan çalışmaların %59 oran ile en sık kullanılan yöntem olduğu bildirilmiştir. Bunu, %26 oran ile makine öğrenimine dayalı çalışmaların takip ettiği bildirilmiştir. Ağız, diş ve çene radyolojisi alanında gerçekleştirilen çalışmalar amaçlarına göre çeşitli gruplar ile kategorize edilebilir. Bu kategoriler; diş çürüklerinin analizi, periapikal patolojiler, periodontal kemik kaybının teşhisi, kist ve tümör sınıflandırması, sefalometrik analiz, osteoporoz

taraması, radyolojik görüntüler üzerinden dişlerin tanınması ve segmentasyonuna yönelik çalışmalar, adli diş hekimliği ve görüntü kalitesi geliştirmesine yönelik çalışmalardır.⁹

Yapay zeka uygulamaları, radyografik görüntülerdeki çeşitli artefaktlar veya düşük kontrast sebebiyle insan gözü tarafından fark edilemeyen aproksimal çürükler ve periapikal patolojiler gibi bazı patolojilerin teşhisine yardımcı olabilmektedir.¹³³ Bu amaçla Devito ve arkadaşları bite-wing radyograflar üzerinden aproksimal çürüklerin teşhisini geliştirmek amacıyla çok katmanlı bir algılayıcı sinir ağı tekniğine dayalı bir sistem önermişlerdir. Araştırmacılar aproksimal çürük teşhisinde %39,4 oranında bir iyileşme bildirmişlerdir.¹³⁴

Literatürde Geetha ve arkadaşları, Yu ve arkadaşları, Ali ve arkadaşları, Li ve arkadaşları, Singh ve Sehgal tarafından makine öğrenimi tekniklerine dayalı sınıflandırıcılar ile çeşitli görüntü işleme tekniklerini kullanan birçok çalışma gerçekleştirilmiştir ve bu çalışmalarda radyograflardaki diş çürüklerini sınıflandırmada % 86 ile 97 arasında değişen doğruluk oranlarıyla yüksek performanslı sonuçlar bildirilmiştir.^{133,135-138}

Literatürde periapikal radyograflar üzerinden diş çürüklerinin yalnızca sınıflandırılması değil teşhisi için derin öğrenme tekniklerinden konvolüsyonel sinir ağlarına dayalı birçok çalışma gerçekleştirilmiştir. Choi ve arkadaşları aproksimal çürük teşhisi için konvolüsyonel sinir ağları ile çeşitli görüntü işleme tekniklerinin bir kombinasyonunu içeren bir sistem önermiştir.¹³⁹ Lee ve arkadaşları ise diş çürüklerinin otomatik olarak teşhis edilebilmesi amacıyla gerçekleştirdiği çalışmasında konvolüsyonel sinir ağı mimarilerinden transfer öğrenmeye dayalı bir sistem önermiştir.¹⁴⁰

Periapikal patolojilerin teşhisi noktasında, bu patolojilerin saptanması ve boyutlarına göre sınıflandırmasını yapmak amacıyla Endres ve arkadaşları, Mol ve van der Stelt tarafından derin öğrenme tekniklerine dayalı bilgisayar destekli yapay zeka sistemleri önerilmiştir.^{141,142}

Flores ve arkadaşları ile Okada ve arkadaşları da makine öğrenimi mimarilerini kullanarak KIBT görüntüleri üzerinde granülomları ve radiküler kistleri ayırt etmek için bilgisayar destekli tanı sistemleri önermişlerdir.^{143,144}

Literatürdeki bu çalışmalarda önerilen sistemlerinin performansı ile deneyimli radyologlar ve çene cerrahları tarafından yapılan manuel teşhisler arasında anlamlı bir fark olmadığı bildirilmiştir.⁹

Periodontal kemik kaybını araştıran yapay zeka temelli araştırmalardan, Lin ve arkadaşları, hibrit özellikli bir mimari kullanılarak kemik kaybının bölümlere ayrılmasıyla periapikal radyograflarda kemik kaybının otomatik olarak lokalize edilebilmesine olanak sağlayan bir sistem geliştirmişlerdir.¹⁴⁵

Aynı araştırmacılar daha sonra yaptıkları bir çalışmada ise alveol kret tepesi, mine-sement birleşimi ve dişlerin konumlarını referans alarak kemik kaybı derecesini ölçmeye yardımcı bir model geliştirmişlerdir.¹⁴⁶

Mikulka ve arkadaşları, Nurtanio ve arkadaşları panoramik radyografları kullanarak, Yılmaz ve arkadaşları ise KIBT görüntülerini kullanarak odontojenik tümörler ve kistler için bilgisayar destekli bir sınıflandırma sistemi geliştirmek amacıyla çeşitli makine öğrenimi yöntemleri kullanılmışlardır.¹⁴⁷⁻¹⁴⁹

Odontojenik kist ve tümörlerin sınıflandırılması amacıyla metodoloji olarak konvolüsyonel sinir ağlarına dayalı birçok çalışma gerçekleştirilmiştir. Poedjiastoeti ve Suebnukarn, panoramik radyograflar üzerinden ameloblastoma ve keratokistik odontojenik tümörlerin tespit edilmesi amacıyla konvolüsyonel sinir ağlarına dayanan bir sistem önermişlerdir.¹⁵⁰

Ariji ve arkadaşları, panoramik radyograflar üzerinden radyolusent lezyonların tespit edilmesi ve sınıflandırılması amacıyla derin öğrenmeye dayanan bir çalışma gerçekleştirmişlerdir. Çalışmaya, ameloblastoma, keratokistik odontojenik tümör, dentigeröz kist, radiküler kist veya basit kemik kistini içeren, çapı 10 mm'den büyük radyolusent lezyonu olan 210 bireye ait panoramik radyograf dahil edilmiştir.¹⁵¹

Watanabe ve arkadaşları tarafınan gerçekleştirilen çalışma ise derin öğrenmenin nesne algılama teknolojisinin panoramik radyograflarda maksilladaki kist benzeri yapıların belirlenmesinde kullanılabilirliğini araştırmak amacıyla gerçekleştirilmiştir. Çalışmaya maksiller bölgede kist benzeri yapıya sahip olan bireylere ait panoramik radyograflar dahil edilmiştir.¹⁵²

Lee ve arkadaşları ise panoramik radyograflar ve KIBT görüntüleri üzerinden derin konvolüsyonel sinir ağları kullanarak keratokistik odontojenik tümör, dentigeröz kist ve periapikal kistlerin tespitini amaçlayan bir çalışma gerçekleştirmişlerdir.¹⁵³

Literatürde odontojenik kist ve tümörlerin üzerinde yapılan makine öğrenimi ve derin öğrenmeye dayalı çalışmaların performansı umut verici olmasına rağmen değişiklik göstermektedir. Bunun sebebinin odontojenik kist ve tümörlerin şekil, yerleşim ve iç yapı olarak çeşitli şekillerde ortaya çıkması ve her zaman benzerlik göstermemesi olduğu öne sürülmüştür.⁹

Yapay zeka teknolojileri ağız, diş ve çene radyolojisinde sefalometrik analiz noktasındaki çalışmalarda da geniş araştırma alanı bulmuştur. Sefalometrik analizde klinisyen üzerindeki yükü azaltmak ve zamandan tasarruf etmek için çeşitli yapay zeka yöntemleri geliştirilmiştir. Anatomik noktaların otomatik olarak tespit edilmesi amacıyla Yu ve arkadaşları, Park ve arkadaşları yaptıkları çalışmalarında derin öğrenme mimarilerine dayanan sistemler önermişlerdir.^{154,155}

Gupta ve arkadaşları 2015 ve 2016 yıllarında gerçekleştirdikleri çalışmalarında yalnızca anatomik noktaların tespiti değil, bilgiye dayalı algoritmalar kullanılarak otomatik sefalometrik ölçüm gerçekleştirmeye yarayan yapay zeka sistemleri önermişlerdir.^{156,157}

Literatürde, yapay zeka ile osteoporoz sınıflandırılması yapılabilmesi amacıyla birtakım çalışmalar gerçekleştirilmiştir. Chu ve arkadaşları ile Lee ve arkadaşları, panoramik radyograflar kullanılarak osteoporozun sınıflandırılması amacıyla metodoloji olarak derin konvolüsyonel sinir ağı mimarilerini kullanarak çeşitli sistemler geliştirmişlerdir. Bu çalışmalarda geliştirilen sistemlerin etkinliği %86 ile %99 arasında değişen oranlarda bildirilmiştir.¹⁵⁸⁻¹⁶⁰

Osteoporoz alanında bilgisayar destekli tanı sistemlerinin geliştirilmesi son yıllarda ümit verici sonuçlar vermiştir. Yakın gelecekte osteoporozun erken saptanması için yapay zeka sistemlerinin klinik kullanıma uygun hale geleceği öne sürülmektedir.⁹

Literatürde, radyografların görüntü kalitesini geliştirmek amacıyla yapay zeka destekli çalışmalar da gerçekleştirilmiştir. Du ve arkadaşları, panoramik

radlyograflarda hasta konumlandırma hatalarından dolayı oluşan düşük kaliteli grntleri dzeltebilen konvolsyonel sinir ađı tabanlı bir mimari nermiřlerdir. Arařtırmacılar, alıřmada nerilen sistem desteđi ile dzeltilmiř panoramik grnt rekonstrksiyonu yapıldıđında grntdeki bulanıklıđın azaldıđını ve grnt kalitesinin ykseldiđini bildirmiřlerdir.¹⁶¹

Liang ve arkadařları, Minnema ve arkadařları, Hegazi ve arkadařları da KIBT grntlerindeki metal artefaktlarını azaltmaya ynelik derin đrenme tekniklerine dayalı alıřmalar yrtmřlerdir.¹⁶²⁻¹⁶⁴

Literatrde derin đrenmeye dayalı teknikler, diř hekimliđi alanında sıkça kullanılmıřtır. Prajapati ve arkadařları dental hastalıkların otomatik teřhisi iin konvolsyonel sinir ađları ve transfer learning mimarilerini kullanmıřlardır.¹⁶⁵ Murata ve arkadařları, Kuwana ve arkadařları, Kim ve arkadařları maksiller sins patolojilerinin teřhisi iin derin đrenme tekniklerinden faydalanmıřlardır.¹⁶⁶⁻¹⁶⁸

Kann ve arkadařları, Arijı ve arkadařları lenf nodu metastazlarının tanımlanması ve sınıflandırması iin derin đrenme sistemlerinden faydalanmıřlardır.^{169,170}

Vinayahalingam ve arkadařları, Fukuda ve arkadařları, Jaskari ve arkadařları, Kwak ve arkadařları, mandibular kanal segmentasyonu ile mandibular nc molar diř pozisyonu arasındaki iliřkinin tespiti amacıyla derin đrenme mimarilerini kullanmıřlardır.¹⁷¹⁻¹⁷⁴

Vranckx ve arkadařları, mandibular nc molar diřlerin otomatik segmentasyonu ve srme potansiyellerini deđerlendirmek amacıyla konvolsyonel sinir ađlarına dayanan bir alıřma gerekleřtirmiřlerdir.¹⁷⁵

Orhan ve arkadařları, gml mandibular nc molarların saptanması zerine derin konvolsyonel sinir ađları ve insan gzlemciler arasındaki uyumu deđerlendiren bir alıřma gerekleřtirmiřlerdir. Arařtırmacılar yapay zeka destekli sistemin %86,2 oranında bir tanısıl dođruluk gsterdiđini ve insan gzlemci ile arasında yksek korelasyon saptandıđını bildirmiřlerdir.¹⁷⁶

Johari ve arkadařları, Fukuda ve arkadařları vertikal kk kırıklarının tespiti iin yapay zeka tekniklerinden faydalanmıřlardır.^{177,178}

Kuwada ve arkadaşları gömülü maksiller süpernümerer dişlerin saptanması ve sınıflandırması için derin öğrenme tekniklerinden yararlanmışlardır.¹⁷⁹

Kise ve arkadaşları da bilgisayarlı tomografi görüntüleri kullanılarak Sjögren sendromlu hastalarda tanı desteği sağlayan derin öğrenmeye dayalı bir sistem önermişlerdir.¹⁸⁰

Bu tez çalışmasında, klasik yaş tahmini metotlarında görülen gözlemci öznelliğinin yaş tahminini etkilemesi, metotların çok fazla zaman ve çaba gerektiren manuel ölçümlere dayanması, metodolojik olarak gerekli örneklem büyüklükleri göz önüne alındığında rutin klinik uygulama zorluğu gibi dezavantajların üstesinden gelmenin bir yolu olarak panoramik radyograflar üzerinden diş yaşının yapay zeka algoritmaları kullanılarak tahmini amaçlanmıştır. Çalışmamız, otomatik biçimde yapay zeka algoritmalarına dayanmakta olup, herhangi bir ön işleme olmaksızın panoramik radyograf görüntüleri kullanılmaktadır ve diş yaşı tespiti için kullanılan yapay zeka algoritmaları herhangi bir ölçüm, manuel hesaplama ve sınıflandırma gerektirmemektedir.

3. GEREÇ VE YÖNTEM

Bu tez çalışmasında, panoramik radyograflar üzerinden, yapay zeka algoritmalarına dayalı teknikler kullanılarak otomatik olarak yaş tahmini yapılması amaçlanmıştır. Verilerden öznitelik çıkarımı 2D-DCNN ve 1D-DCNN teknikleri kullanılarak gerçekleştirilmiştir. Öznitelik bilgilerini kullanarak yaş tahmini gerçekleştirmek için ise GA ve RF algoritması modifiye edilerek birleştirilmiş ve MG-RF olarak tanımlanmıştır.

3.1 Hasta Seçimi ve Veri Kümesinin Oluşturulması

Bu tez çalışmasına, Pamukkale Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı arşivinde, 1 Mart 2020- 1 Mart 2022 tarihleri arasında fakültemizde doğru pozisyonda çekilmiş, artefakt ve distorsiyon olmayan, net değerlendirilebilen panoramik radyografi bulunan, herhangi diş eksikliği ve dental restorasyonu bulunmayan, sistemik olarak sağlıklı 6 ile 15 yaşları arasındaki tüm hastalar dahil edilmiştir. Kronolojik yaş, panoramik radyografin çekildiği tarihten hastanın sisteme kayıtlı olan doğum tarihi çıkarılarak hesaplanmıştır.

Bu çalışma için Pamukkale Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu tarafından onay alınmıştır (E-60116787-020-202083) (Ek-1). Çalışma, Helsinki Bildirgesi prensiplerine uygun olarak yapılmıştır.

Panoramik radyograflar, Dijital Ortopantomograf (OP200D; Instrumentarium Şirketi, Görüntüleme Birimi, Tuusula, Finlandiya, 66 kVp 2,5 mA 13,4 sn ve 60 kVp, 6,3 mA 14,1 sn aralığındaki pozlama değerleri ile elde edilmiştir. Panoramik radyograflar yapay zeka algoritmaları kullanılarak retrospektif olarak değerlendirilmiştir.

3.2 Çalışmanın Genel Akış Diyagramı

Tıbbi görüntü analizi için bilgisayarlı modelleme sistemlerinin hem klinik uygulamalar hem de bilimsel araştırmalar üzerinde büyük etkileri vardır. Derin öğrenme algoritmaları; söz konusu görüntülerdeki morfolojik ve/veya yapısal kalıpların algılanması ve tıbbi görüntü analizinde yeni bir yaklaşım olmuştur. Derin öğrenme algoritmalarının; büyük veri setlerini işleme kapasitesi ve farklı tıbbi

uygulamalardaki başarımı nedeniyle tıbbi bilgi işlem alanındaki kullanımını artırmıştır.¹⁸¹ Bu nedenle, çalışmamızda öznitelik çıkarımı gerçekleştirmek için derin öğrenme algoritmalarından, 1D-DCNN ve 2D-DCNN modelleri kullanılmıştır.


Çalışmanın giriş veri kümesini oluşturmak üzere çalışmaya dahil edilme kriterlerini sağlayan panoramik radyograflar, dişlerin gelişimi değerlendirilerek yapılan klasik yaş tayini metodlarının en sık kullanılan metodları olan Demirjian ve Willems metodlarının incelediği, sol yedi mandibular daimi dişi içeren bölgeyi kapsayacak şekilde manuel bir biçimde, Adobe Photoshop CC 2021 (Adobe Sistemleri Anonim Şirketi, California, Amerika Birleşik Devletleri) yazılımı kullanılarak kırılmıştır. Çalışmanın gerçekleştirilmesi için, ilk olarak veri kümesini oluşturan panoramik radyograflar ve hasta kayıtları sisteme yüklenmiştir. Panoramik radyograflar iki boyutlu veri olduğu için 2-DCNN algoritmasına, hastalara ait kronolojik yaş bilgilerini içeren hasta kayıtları ise tek boyutlu veri olduğu için 1-DCNN algoritmasına tabi tutulmuştur.

Daha sonra verilerin yorumlanması ve kullanılmasını kolaylaştırmak için giriş verisini oluşturan panoramik radyograflar ön işleme sürecine tabi tutulmuştur. Ön işleme adımında, panoramik radyografların algoritma tarafından uygun biçimde işlenebilmesi için standart hale getirilmesi ve boyut uygunluğu sağlanmaktadır. Bu adımda, giriş verisinin ham veri özellikleri değiştirilmeksizin ön işlemeye tabi tutulması, yaş tahmini yapılırken gerçekleştirilecek insan hatalarının veya gözlemci öznelliğinin neden olabileceği hataların, herhangi bir eksik veya yanlış veri girişinin önlenmesine de yardımcı olmaktadır.

Ön işleme sürecini takiben öznitelik seçimi ve zenginleştirilmesi adımları; incelediğimiz radyograflar ve hasta kayıtlarından oluşan veri setinin karmaşıklığını, çekim sırasında görülen bozuklukları ve gürültü sorunlarını azaltmak ve sınıflandırıcının performansını artırmak üzere yapılmaktadır. Veri kümesinin eğitilmesi, akıllı modellerin sistemi algılaması ve başarımını sağlaması açısından önemlidir. Çalışmamızdaki modelde, ana bloklar 1D-DCNN ve 2D-DCNN bloklarıdır. Diğer adımlar başarımı artırmak amacı taşımaktadır. Öznitelik zenginleştirilmesi ve eğitimi adımları MG-RF ile sınıflandırma performans metriklerinin hesaplanması ile sonlandırılmıştır.

Genel anlamda, panoramik radyograflardan öznitelik çıkarmak için 2D-DCNN algoritması kullanılmıştır. Eşzamanlı olarak ise hasta kayıtlarından öznitelik çıkarmak için 1D-DCNN algoritması kullanılmıştır. MG-RF bloğunda ise daha iyi yaş tahmini yapılabilmesi amacıyla panoramik radyograflardan ve hasta kayıtlarından yapay zeka yöntemleriyle belirlenen özniteliklerden uygun olanlar birleştirilmiştir. Son adım olarak ise, bu çalışmada kullanılan sistemin etkinliğini mevcut yöntemlerle doğrulamak için performans metrikleri kullanılmıştır.

Çalışmamızdaki metodolojilerle, Şekil 3.1'de gösterilen akış diyagramındaki işlem sırası ile yaş tahmini yapılmaktadır. İlerleyen kısımlarda bu işlemler detaylı bir biçimde açıklanmaktadır.



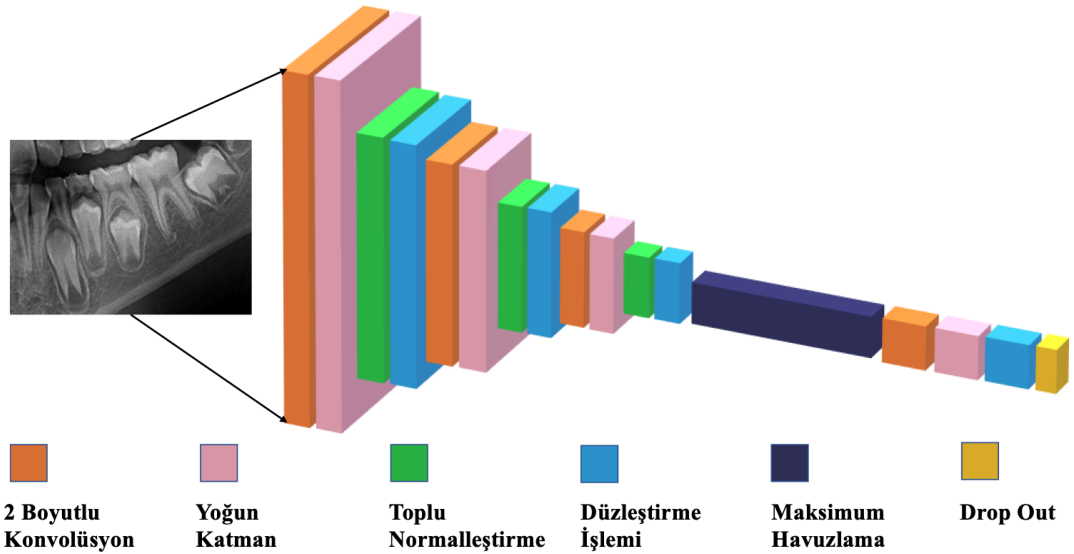
Şekil 3.1 Çalışmamızın genel akış diyagramı

3.2.1 İki boyutlu Derin Konvolüsyonel Yapay Sinir Ağı (2D-DCNN):

2D-DCNN, 2 boyutlu konvolüsyonel yapay sinir ağı modelidir. Çeşitli uygulamalarda geniş kullanım alanı bulmuştur. Çok sayıda avantajı olan bir modeldir. Başlıca avantajları şunlardır:

- 2D-DCNN modelleri, öznitelik çıkarma ve zenginleştirme sürecini tek bir öğrenme gövdesine entegre etme yeteneğine sahiptir. Eğitim aşamasında öznitelikleri doğrudan ham girdi üzerinden optimize etmeyi öğrenebilir.
- 2D-DCNN, bağlı ağırlıklarla seyrek olarak ilişkili olduğu için büyük girdileri yüksek hesaplama verimliliği ile işleyebilir.
- 2D-DCNN modelleri ayrıca sisteme girdi olarak sunulan verilerdeki çeviri, eğrilik, ölçeklendirme, distorsiyon gibi bozulmalara karşı iyi gelişmiştir.
- 2D-DCNN'ler farklı girdi boyutlarına uyum sağlayabilir.¹⁸²

Genel mimarisi Şekil 3.2'de gösterildiği gibi, 2D-DCNN modeli çok sayıda katmanı içermektedir. Standart katmanlar; konvolüsyon, toplu normalleştirme (batch normalisation), maksimum havuzlama (maxpooling), bırakma (drop-out), düzleştirme (flatten) ve yoğun katman (dense layer) olarak tanımlanmaktadır.



Şekil 3.2 2D-DCNN'nin genel mimarisi. (Buradaki kaskad bağlı bloklar sırasıyla: 2 Boyutlu Konvolüsyon, Yoğun Katman, Toplu Normalleştirme, Düzleştirme İşlemi, Maksimum Havuzlama ve Drop-out olarak tanımlanmıştır.)

Çalışmamızda panoramik radyograf görüntülerinden öznitelik çıkarımı, aşağıdaki prosedüre göre 2D-DCNN tarafından gerçekleştirilir.

I. Giriş Katmanı

Ön işleme tabi tutulmuş verilerden gelen öznitelikler, 2D-DCNN'nin girdisi olarak bildirilmekte ve denklem.1 ile verilmektedir.

$$\text{Denklem.1: } x = [x_1, x_2, x_3 \dots x_{\text{numF}}]$$

Burada x_{numF} değeri, hesaplamadan sonra pencere başına öznitelik sayısını temsil etmektedir.

Modelin yakınsama hızını artırmak için, bireysel veri boyutundaki değerlerin doğrusal olarak dönüştürüldüğü minimum-maksimum normalleştirme (denklem.2'de gösterildiği gibi) kullanılır. Daha sonra [0, 1] aralığına normalleştirilir.

$$\text{Denklem.2: } x = \frac{x - \min}{\max - \min}$$

Denklem.2'de min değeri bireysel sütunun minimumunu temsil ederken, max değeri ise bireysel sütunun maksimumunu temsil etmektedir.

II. Konvolüsyon Katmanı

Konvolüsyon katmanının üzerinde yer alan j. öznitelik matris bileşeninin çıktısı denklem.3 ile verilmiştir.

$$\text{Denklem.3: } x_i^{l,j} = \sigma \left(b_j + \sum_{a=1}^m w_a^j x_{i+a-1}^{l-1,j} \right)$$

Burada; b_j baz değerinin j. öznitelik bileşeni için ilk değeri, m kernel boyut değeri ile gösterilmekte, w_a^j öznitelik ağırlık katsayısını j'nin bileşenini göstermekte, a değeri filtre indeksini temsil etmekte ve σ değeri aktivasyon fonksiyonunu temsil etmektedir.

III. Maksimum Havuzlama Katmanı

Havuzlama katmanı, $x_i^{l,j}$ değerinin bitişik sonucu için toplama ölçümlerini azaltır. Bu işlem, ölçeğin değişmeyen öznitelik bakımını gerçekleştiren çıktı

hassasiyetinin yanı sıra boyutu da en aza indirmeye yardımcıdır. Bu çalışmada kullanılan maksimum havuzlama işlemi, konvolüsyon katmanın çıktı özniteliklerini çeşitli bölümlere ayıran ve her bir bölümdeki maksimum değeri belirleyen havuzlama işlevidir. Bu katmanın çıktısı denklem.4 ile verilmektedir.

$$\text{Denklem.4: } x_i^{l,j} = \max_{\text{pos}=1}^r \left(x_{(i-1)*T_{ps}}^{l-1,j} \right)$$

Denklem.4'te T değeri havuzlama adımını, ps değeri havuzlama boyutunu ve r değeri reel sayıları temsil etmektedir.

IV. Eğitim Süreci

2D-DCNN modeli, Conv2D, toplu normalleştirme, maksimum havuzlama, bırakma, düzleştirme ve yoğun katman gibi çok sayıda katmandan meydana gelir. Farklı katman işlemleri tamamlandıktan sonra en son adım olan yoğun katmanda ise nihai tahmini gerçekleştirmek için alt katmandan öğrenilen yerel yapının çeşitli özelliklerini entegre edilir.¹⁸² Çalışmamızdaki DCNN modelinde tek bir konvolüsyon katmanı çifti ve maksimum havuzlama katmanı kullanılmıştır. Daha sonra 2 boyutlu veriler 1 boyutlu verilere düzleştirilmiştir. Bu şekilde genel sinir ağı, yoğun katman ile tamamlanmıştır. Bu model denklem.5 ile verilmiştir.

$$\text{Denklem.5: } f(x) = \text{argmax}_{\text{cls}} \left(\frac{e^{x^{l-1} w_j}}{\sum_{n=1}^N e^{x^{l-1} w_{ps}}} \right)$$

Denklem.5'te cls değeri sınıf etiketini, x değeri bir örneğin özniteliklerini, l değeri katman indeksini ve N değeri sınıf sayısını göstermektedir. Ayrıca, ileri doğru yayılmalar denklem.3 ve denklem.5'e göre işlenmiştir.

Veri matrisinin taşıdığı bilgi giriş katmanından çıkış katmanına ileriye doğru çoğalır, böylece tüm ağın çıktısı gerçekleşir. Ayrıca, ileri yayılımın bir yinelemesi (iterasyonu), ağ hatası değerini karşılayacaktır. Çapraz entropi maliyet fonksiyonu hata değeri denklem.6'da verilen şekilde hesaplanmıştır.

$$\text{Denklem.6: } L(y) = -\frac{1}{n} \sum_x [y \ln a + (1 - y) \ln(1 - a)]$$

Denklem.6'da x değeri örneği, n değeri toplam eğitim örneklerini, y gerçek yaş değerini, a değeri ise tahmin edilen yaş değerini temsil etmektedir.

Çalışmamızda, panoramik radyograf görüntüleri başlangıçta girdi olarak alınmıştır ve kayar pencere işlemi gerçekleştirilmiştir. Bunu takiben, öznitelikleri çıkarılmıştır. Daha sonra bu öznitelikler denklem.2 kullanılarak normalleştirilmiş ve düzenlenmiştir. Ardından, ağırlık yakınsayana kadar ileri ve geri yayılım gerçekleştirilmiştir. Son olarak, öznitelik tahmin etmek için bu eğitilmiş model kullanılmıştır. 2D-DCNN'nin genel algoritması Algoritma-1 Tablo 3.1'de verilmiştir.

Tablo 3.1 2D-DCNN'nin genel algoritması

Algoritma-1: 2D-DCNN
Girdi: Panoramik Radyograf Görüntüleri, Çıktı: Öznitelikler
Adım 1: Kayar Pencere İşlemi
Adım 2: sef ← Özniteliklerinin Çıkarılması
Adım 3: Denklem.2 kullanılarak özniteliklerini normalleştirilmesi düzenleme özelliği verileri,boyut=64 Units-128 Units
Tekrar:
Adım 4: İleri Yayılım cdf ← Convolution2D(sef); mp ← Max_pooling(cdf); fc ← Fully_connected(mp); class label ← relu(fc);
Adım 5: Geri Yayılım: Adım 5 ile geri yayılım yapılması; Until wi convergences;// wi:weight
Adım 6: Eğitilmiş ağız öznitelik tahmini için kullanımı

3.2.2. Tek Boyutlu Derin Konvolüsyonel Yapay Sinir Ağı (1D-DCNN):

Bir konvolüsyonel sinir ağı türü olarak tek boyutlu derin konvolüsyonel yapay sinir ağları, genel olarak konvolüsyonel sinir ağlarının temel özelliklerine sahiptir.¹⁸³ 1D-DCNN sistemlerinin, sınırlı miktarda veri üzerinde iyi performans göstermesi, 2D-DCNN ve diğer derin öğrenme mimarilerine kıyasla düşük hesaplama karmaşıklığı, daha hızlı eğitim süreci ve ilgili öznitelikleri sırayla çıkarma yeteneği gibi çeşitli avantajları vardır. Düşük maliyetli ve gerçek zamanlı uygulamalar için uygun bir modeldir.¹⁸⁴

1D-DCNN sistemlerindeki ana değişiklik, 2D-CNN'lerde iki boyutlu konvolüsyon matris bilgisi çalıştırılırken, bu modelde tek boyutlu konvolüsyon yani vektör bilgisi çalıştırılmasıdır. Denklem.7'de gösterildiği şekilde ifade edilebilir:

$$\text{Denklem.7: } x_1 = \text{conv1d}(w_{1-1}, x_{1-1}) + b_1$$

Denklem.7'de x_1 değeri x_{1-1} değerinin sonuçlarını temsil etmekte ve b_1 değeri ise sapmayı göstermektedir.

Gerçek fonksiyona daha iyi uyması için sisteme doğrusal olmayan fonksiyonlar eklenir. Dolayısıyla, genel sonuç denklem.8'deki gibi gösterilir:

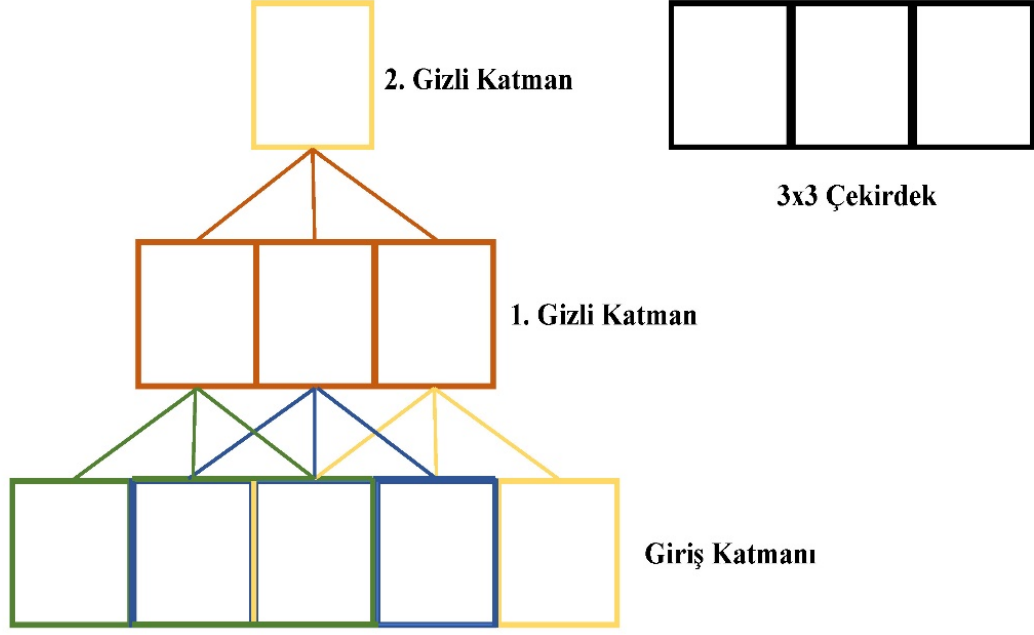
$$\text{Denklem.8: } y_1 = f(x_1)$$

Denklem.8'de $f(x_1)$ ReLU'yu, aktivasyon fonksiyonlarını veya sigmoid fonksiyonlarını temsil etmektedir.

DCNN'lerdeki temel kavramlardan biri de girdi verilerinin konvolüsyonel sinir ağlarının özellikleri tarafından görüntülenebildiği bölgeyi temsil eden alıcı alanlar olarak adlandırılan kavramdır. Konvolüsyonel ağlarda bir birim girdinin yalnızca bir bölgesine bağlıdır. Girdideki bu bölge, o birim için alıcı alandır. Alıcı alan kavramı, konvolüsyonel sinir ağlarının ne kadar derin çalıştığını anlamak ve teşhis etmek için önemlidir.¹⁸⁵

Bir giriş görüntüsünün, bir birimin alıcı alanı dışındaki herhangi bir yeri o birimin değerini etkilemediğinden, ilgili görüntü bölgesinin tamamını kapsadığından emin olmak için kapsamı alanının dikkatli bir şekilde kontrol edilmesi gereklidir. Girdi görüntüsündeki her bir piksel için bir tahmin yapılan semantik görüntü segmentasyonu, stereo ve optik akış tahmini gibi yoğun tahmin içeren görevlerde, hiçbir önemli bilginin dışarıda bırakılmaması için her çıkış pikselinin büyük bir alıcı alana sahip olması kritiktir.¹⁸⁶

Tek boyutlu konvolüsyonel sinir ağlarında, Şekil 3.3'te gösterildiği gibi, (3×1) çekirdek boyutu kullanıldığında, ilk gizli katman üç karakteristik orijinal veri değerini görebilmekte, ardından gelen gizli katman beş karakteristik orijinal veri değerini görebilmektedir. Böylece, (5×1) boyutlu tek konvolüsyon çekirdeği yerine iki (3×1) konvolüsyon çekirdeği kullanılmasıyla, benzer alıcı alanın elde edildiği teyit edilirken kullanılan parametreler en aza indirilmektedir. Bu fikre uygun olarak, aşağıdaki blok, öznelikleri çıkarmak için çok sayıda küçük çekirdeğin kullanılmasıyla çerçevelemiştir.



Şekil 3.3 1D-DCNN'nin çalışma süreci

3.2.3. Öznitelik Birleştirme

Panoramik radyograf görüntülerinden ve hasta kayıtlarından öznitelikler çıkarıldıktan sonra birleştirilmiş ve yaş tahmini için eğitim ve test kümelerine beslenmiştir. Çalışmamızda panoramik radyograf görüntülerinin toplam sayısı 622'dir. Dolayısıyla bu görüntülerle eşleşen toplam hasta kaydı sayısı da 622'dir. Öznitelik çıkarımı adımımda 622 panoramik radyograf görüntüsünden 60 öznitelik çıkarılırken, 622 hasta kaydından 15 öznitelik çıkarılmıştır. Birleştirme sırasında, Tablo 3.2'de gösterildiği gibi toplam 75 birleştirilmiş öznitelik elde edilmiştir.

Tablo 3.2 Öznitelik Birleştirme

	Toplam Panoramik Radyograf Sayısı	Toplam Hasta Kaydı Sayısı
	622	622
Öznitelik Çıkarımı Sonrası	60	15
Birleştirilmiş Öznitelik		75

3.3. Modifiye Genetik-Rastgele Orman Algoritması (MG-RF)

3.3.1 Genetik Algoritma

Genel olarak GA, biyolojik sistemlerde Darwin'in genetik teorisine dayanan genel amaçlı bir optimizasyon arama algoritmasıdır. GA evrimsel biyolojideki doğal

seçilim, çaprazlama, mutasyon gibi kavramlar temel alınarak geliştirilmiştir. Geleneksel algoritmalarla çözülmesi güç olan veya birden fazla amaç içeren problemlerin çözülmesinde en uygun çözümün belirlenmesine yardımcı olmak için kullanılmaktadır.¹⁸⁷

Genetik Algoritmaların farklı uygulamalarının ayrıntıları farklılık gösterse de tipik olarak aşağıdaki yapıyı paylaşırlar. Algoritma, popülasyon adı verilen bir hipotez havuzunu iterasyonlu bir şekilde güncelleyerek çalışır. Her iterasyonda, popülasyonun tüm üyeleri uygunluk fonksiyonuna göre değerlendirilir. Daha sonra mevcut popülasyondan en uygun bireylerin rastlantısal olarak seçilmesiyle yeni bir popülasyon oluşturulur. Bu seçilmiş bireylerden bazıları bozulmadan sonraki nesil popülasyona taşınır. Diğerleri ise çaprazlama ve mutasyon gibi genetik işlemler uygulanarak yeni yavru bireyler oluşturmak için temel olarak kullanılır.¹⁸⁵

GA'nın ana prosedürleri şu şekilde açıklanabilir. İlk olarak bir kromozom popülasyonu oluşturulur. Popülasyondaki her bir kromozom, spesifik bir problemin çözümüne aday bir çözümü temsil etmektedir. Bu kromozomlar birden çok genden oluşur. Algoritma, evrim sürecini rastgele bir kromozom popülasyonu ile başlatır. Mevcut popülasyondaki tüm kromozomlar, optimizasyon hedefini temsil eden belirli uygunluk fonksiyonu tarafından değerlendirilir. Kromozomların uygunluk değerlerinde göre, ilgili popülasyonu gelişmiş çözümlere doğru geliştirmek amacıyla seçilim, çaprazlama, mutasyon gibi bir dizi genetik faktör uygulanır. Birçok iterasyondan sonra GA en uygun bireyi elde eder ve bu da problemin optimal çözümünü temsil eder.¹⁸⁸

3.3.2 Karar Ağaçları ve Rastgele Orman Algoritması

İstatistiksel yöntemler ile ya da yapay sinir ağları ile mevcut veriler üzerinden öğrenilen fonksiyonların insanlar tarafından anlaşılabilir bir kural veya yöntem olarak yorumlanması zordur. Karar Ağacı öğrenimi, öğrenilen işlevin bir karar ağacı tarafından temsil edildiği, ayrık değerli hedef işlevlerin yaklaşık olarak belirlenmesi için kullanılan bir yöntemdir. Öğrenilmiş ağaçlar, insan tarafından anlaşılabilirliği artırmak için eğer/öyleyse kural kümeleri olarak yeniden temsil edilebilir.¹⁸⁵

Karar Ağacı, gerçekleştirilecek tüm olası seçenekleri, bu seçeneklere etkisi bulunabilecek tüm faktörleri, bu faktörlere bağlı gerçekleştirilecek tüm olası sonuçları

veri kümesine bağlı olarak değerlendiren grafiksel bir teknik olarak tanımlanabilmektedir. Veri kümesinden Karar Ağacı oluşturulduktan sonra, problemin çözümüne yönelik uzman bir kişiye gösterilip uygulama sonucunun anlamlı olup olmadığı denetlenebilir. Veri madenciliği uygulamalarında yaygın kullanım alanı bulan Karar Ağacı uygulaması ile ön çalışma yapmak, sonradan başka bir teknik kullanılacak olsa bile ilgili problemin çözümüne yönelik önemli değişkenler ve olası kurallar açısından uygulayıcıya değerli bilgiler sunmaktadır.¹⁸⁵

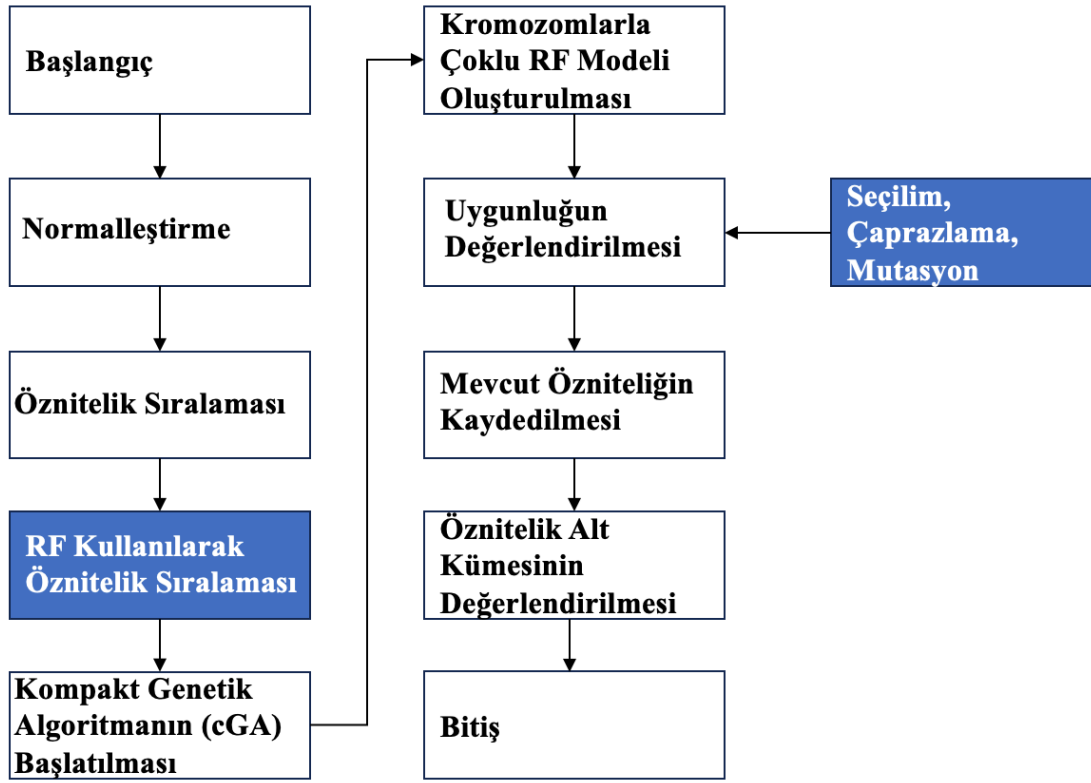
Rastgele Orman Karar Ağacı algoritmasında, veri kümesinden çıkarılan en iyi özniteliklerden seçilmiş düğümler dallara ayrılmaz. Her bir düğümdede, rastgele alınan özniteliklerin en iyisi seçilerek tüm düğümler dallara ayrılır. Her veri kümesi, asıl veri kümesinden yeniden üretilmektedir. Karar Ağaçları rastgele öznitelik seçimiyle geliştirilmektedir ve bu algorithmada budama işlemi yapılmamaktadır. Bu özellikleri sayesinde RF algoritması ile diğer algoritmalara göre hızlı ve doğru sonuçlar elde edilmektedir.^{189,190}

Çalışmamızda bireysel kromozom, Karar Ağacı'nın bir kombinasyonunu gösterir. Bu nedenle bireysel kromozomun uzunluğu toplam Karar Ağacı'nı temsil etmektedir. Bit 1 değerine sahip olduğunda Karar Ağacı korunur; 0 değeri aldığıında ise bu Karar ağacının reddedildiğini gösterir.

Öte yandan, RF algoritması, karar ağaçları geliştirilirken yapılan modelleme için ek rastgelelik içermektedir.

Düğüm ayırma sırasında önemli özelliği aramak yerine, rastgele özellik alt kümesi içindeki uygun öznitelik aranmaktadır. Bu da kapsamlı çeşitliliğe ve daha iyi bir model oluşturulmasına yol açmaktadır.

Bahsedilen avantajlar nedeniyle çalışmamızda, yaş tahmini gerçekleştirilmesi amacıyla GA ve RF algoritmaları birlikte kullanılmış ve Modifiye Genetik Rastgele Orman algoritması olarak adlandırılmıştır. Modifiye Genetik Rastgele Orman algoritmasının (MG-RF) genel iş akışı Şekil 3.4'te sunulmuştur.



Şekil 3.4 MG-RF genel iş akışı

Başlangıçta, öznitelikler, veri kümesindeki sayısal sütun değerlerinin değer aralıklarındaki varyasyonları bozmadan ortak forma değiştirildiği biçimde normalize edilmiştir. Normalleştirme işlemi, bir modelin öğrenme zorluklarını çözmeye yardımcı olan bir adımdır. Bundan sonra, önemli özniteliklerin dikkate alınması için RF algoritması kullanılarak öznitelik sıralaması yapılmıştır.

Bunu takiben, cGA başlatılmıştır. cGA, popülasyonun çözüm kümesi üzerinde bir olasılık vektörü olarak temsil edildiği bir algoritmadır. Bu algoritma ile problemlerin çözümü, daha az miktarda bellek ihtiyacı duyan düzgün dağılım, çaprazlama yöntemini kullanılarak, basit GA'nın birincil mekanizmasına çok benzer bir şekilde gerçekleştirilir.¹⁹¹

Daha sonra, kromozomlarla çoklu RF modelleri oluşturulmuştur. Ardından GA'nın seçim, çaprazlama ve mutasyon süreçleri kullanılarak uygunluk değeri değerlendirilmiştir. Bu işlemler, kaliteyi iyileştirmek için, kromozomun başlangıç popülasyonunu dönüştürür. Seçim, sonraki nesiller için yavrular geliştirmek için çiftleşen ve daha sonra tekrar bir araya gelen ebeveynleri seçen süreci temsil eder. Bu süreç en iyi çözümlerin elde edebileceği GA'nın yakınsaması için hayati önem taşır.

Seçilim süreci, kromozom evrimini kontrol etmek için uygunluğu kullanır. Maksimum uygunluk, optimal çözümleri seçmek için daha fazla şans sağlar. Çaprazlama, bu işlem için seçilen seçkin pozisyonun yanı sıra genetik materyalin sisteme entegrasyonunu ifade eder. Ayrıca, bireysel pozisyonda kromozom için mutasyon işlemi de kullanılır.

Son olarak ise uygunluk değeri değerlendirilmiş, mevcut öznelikler kaydedilmiş ve öznelik alt kümesi değerlendirilmiştir. Uygunluk işlevi spesifik bir problemin çözümü için kromozom kalitesini iyileştirmektedir. Bu nedenle, GA daha iyi yaş tahmini elde etmede yardımcı olmaktadır. GA'nın genel akışı Algoritma-2, Tablo 3.3'te gösterilmiştir.

Tablo 3.3 Genetik Algoritma

Algoritma-2: Genetik Algoritma

Girdi: (it,n,GA Parametreleri)

Adım 1: Başlangıç

Adım 2: $c=0$ ve $i=0$ 'ın başlatılması

Adım 3: Üretim: rastgele çözüm üretilmesi

Adım 4: Uygunluk ve Nesil c hesaplanması

Adım 5: Yeterli uygunluğa ulaşılmadığında i iterasyonlar için hesaplama yapılması

Nesil $c+1$ 'in evrimleştirilmesi

Adım 6: Uygunluk ve Nesil c hesaplanması;

$i=i+1$;

Sonlandırma

Dönüş (Çözüm uygunluğu)

Sonlandırma

Algoritma-2'nin başlangıcında, parametreler başlatılmıştır ve rastgele çözümler üretilmiştir. Daha sonra, uygunluk ve nesil hesaplanmıştır. Uygunluk değeri yeterli düzeyde bulunmadığında, en iyi uygunluk çözümüne ulaşılan kadar iterasyon yapılmıştır. Uygun değer bulunduktan sonra, elde edilen en iyi uygunluk değeri kullanılarak en iyi parametrelere ulaşılmıştır. Bu işlemlere karşılık gelen Algoritma-3 Tablo 3.4'te gösterilmiştir.

Tablo 3.4 Uygunluk Hesaplaması

Algoritma-3: Uygunluk Hesaplaması

Girdi: Veri Kümesi (D), Kromozom

Çıktı: Rastgele Ormana Ait MAE

Adım 1: Başlangıç

Adım 2: Veri Kümesinin sisteme yüklenmesi

Adım 3: kvalues,num_{trees},mtry by decoding (Chromosome);Dc - decompose the set as (Ds,kvalues) kodlarının çözülerek hesaplanması

Adım 4: Uygunluk hesabı için model oluşturulması (RF fit (Dc,num_{trees},mtry))

Adım 5: RF Regressor'u kullanarak öznitelik sıralanması

Adım 6: MAE'nin model üzerinden değerlendirilmesi

Adım 7: Dönüş MAE hesaplanması

Sonlandırma

Algoritma-3'te ilk olarak veri seti ve kromozom girdi olarak alınmıştır. Sonra kvalues,num_{trees}, mtry kodu çözülerek hesaplanmıştır. Bunu takiben, kümeler ayrıştırılmıştır. Daha sonra uygunluk modeli belirlenmiştir. Bu işlemten sonra, öznitelikler RF regresörü kullanılarak sıralanmıştır. Ardından, modelin MAE'si değerlendirilmiştir. Son olarak, en iyi parametreler Tablo 3.5'te gösterildiği gibi GA'dan elde edilmiştir.

Tablo 3.5 Genetik Algoritmadan Çıkarılan En İyi Parametreler

Genetik Algoritmadan Çıkarılan En İyi Parametreler

max_depth'	[10]
max_features'	[sqrt']
min_samples_leaf'	[4]
min_samples_split'	[10]
n_estimators'	[600]

En iyi parametrelerin çıkarılmasından sonra, Algoritma-4'e dayalı olarak optimize edilmiş çözüm elde edilir. Algoritma-4, Tablo 3.6'da sunulmuştur. İlk başta girdi dikkate alınır. Daha sonra uygunluk değeri hesaplanır. Bunu takiben uygunluk değeri değerlendirilir ve döndürülür. Ardından, çözümü belirlemek için uygunluk değerleri hesaplanır. Daha sonra RF algoritması için hiperparametreler elde edilir. Elde edilen hiperparametreler Tablo 3.7'de verilmiştir.

Tablo 3.6 Optimize edilmiş RF

Algoritma-3: Optimize Edilmiş RF

Girdi: minK,maxK,minNTree,maxNTree,treeIncrement,RF best,RF fit
Çıktı: Optimize Edilmiş RF

Adım 1: Başlangıç
Adım 2: Uygunluk(lar) ve Nesil c hesaplanması
Adım 3: Uygunluğun değerlendirilmesi ve tekrarlanması
Adım 4: MAE (En uygun RF ile)
Adım 5: En uygun RF = Optimize edilmiş RF
Adım 6: Optimize edilmiş RF= Çözüm
Sonlandırma

Tablo 3.7 RF için hiperparameteler

RF İçin Hiperparametreler

'max_depth'	[10, 20, 30, 40, 50, 60, 70, 80, 90, 100, None],
'max_features'	['auto', 'sqrt'],
'min_samples_leaf'	[1, 2, 4],
'min_samples_split'	[2, 5, 10],
'n_estimators'	[200, 400, 600, 800, 1000, 1200, 1400, 1600, 1800, 2000]

Optimize edilmiş RF algoritması, Algoritma-4'ün ana aşamaları aşağıda özetlenmiştir:

1. Adım: MG-RF algoritması, uygunluk değerinin Genetik Algoritma ile değerlendirildiği yerde eğitilmiştir. Bu aşamada, elde edilen sınıflar GA'ya göre optimize edilmektedir ve bir ormandaki tek tek ağaçların uygunluğunu hesaplayan RF için girdi elde edilmektedir. Bu işlemde, optimize edilmiş ağaçlar belirlenene kadar iterasyona devam edilmektedir.

2. Adım: Uygunluk Hesaplanması

Bu aşamada, RF'deki ağaçların genel uygunluğu, kromozomların kodunun çözülmesi yoluyla "num_trees,kvalues,mtry" değerlerine dayalı olarak değerlendirilmiştir. 2. adımdan elde edilen ayrıştırılmış sınıf, MAE puanına karşılık gelen sıralanmış özelliklerle, uygunluk değeri açısından değerlendirilmiştir.

3. Adım: Optimize Edilmiş RF

Optimize edilmiş RF; doğal seçim, çaprazlama, mutasyon sürecinin yardımıyla GA'nın sisteme entegrasyonu ve çoklu sınıf ayrıştırmaları ile elde edilmiştir.

4. Adım: Sonlandırma

Optimum RF elde edildikten sonra işlem sonlandırılmıştır.

5. Adım: Sonuç

Bu aşama, yaşı tahmin etmek için öngörülen verilerden oluşmaktadır.

4. BULGULAR

Çalışmamızda, bireylerin panoramik radyografları üzerinden yapay zeka algoritmaları kullanılarak yaş tahmini yapılması amaçlanmıştır.

Bu bölümde, Keşif Verisi Analizi ve çalışmamızda kullanılan sistemin yürütülmesi yoluyla elde edilen bulgular, değerlendirilen performans metrikleriyle birlikte sunulmaktadır.


4.1 Keşif Verisi Analizi

Veri madenciliği, büyük boyutlardaki veri setlerinde, veri tabanlarında ya da veri ambarlarında bulunan veriler içindeki klasik yöntemlerle görülemeyen ve sıradan olmayan öznitelikleri, örüntüleri ve bunların arasındaki ilişkileri ortaya çıkarmak amacıyla istatistiksel ve matematiksel yöntemler, derin öğrenme ve makine öğrenimi teknikleri, bilgisayar programlarının kullanılmasıyla analizi ve sonuçların anlamlı bir şekilde özetlenmesi ve görselleştirilmesi süreci olarak tanımlanır.¹⁹²

Veri Madenciliğinde, Keşif Verisi Analizi, önemli öznitelikleri görsel tekniklerle sonuçlandırmak adına veri kümelerini değerlendirmek için geliştirilen bir stratejidir.¹⁹³

Modelleme yapılmadan önce veri kümesinde bulunan bilgilerin kapsamlı bir görünümünü sağlamaktadır. Çalışmamızda Keşif Verisi Analizi, veri seti içerisindeki panoramik radyograflar ve hasta kayıtları ile gerçekleştirilmektedir.

Veri setimizi oluşturan panoramik radyograflardan ön işleme tabi tutulmuş bazı örnek görüntüler şekil 4.1'de gösterilmektedir. Ayrıca veri setimizden hastaların doğum tarihi, panoramik radyograf çekim tarihi, yaşı, cinsiyetini içeren örnek hasta kayıtları tablo 4.1'de gösterilmiştir.



Şekil 4.1 Veri kümesinden örnek panoramik radyograf görüntüleri

Tablo 4.1 Veri setini oluşturan hasta kayıtlarına ait örnekler

Doğum Tarihi	Panoramik Radyograf Tarihi	Ay Cinsinden Yaş	Yıl Cinsinden Yaş	Cinsiyet
22.02.2013	11.02.2022	107	8,916666667	Erkek
05.05.2011	08.04.2021	119	9,916666667	Erkek
27.10.2011	01.09.2020	106	8,833333333	Erkek
17.02.2014	12.04.2021	85	7,083333333	Erkek
02.01.2008	14.02.2020	145	12,083333333	Erkek
20.08.2013	09.08.2021	95	7,916666667	Kadın
15.05.2014	13.07.2021	85	7,083333333	Kadın
25.10.2007	03.02.2020	147	12,25	Erkek
30.12.2010	06.07.2021	126	10,5	Erkek
15.09.2011	08.04.2021	114	9,5	Erkek
05.07.2007	01.07.2020	155	12,916666667	Kadın
09.02.2014	01.12.2021	93	7,75	Erkek
20.07.2007	05.02.2021	162	13,5	Erkek
24.07.2007	02.02.2022	174	14,5	Erkek
17.01.2014	30.01.2020	72	6	Erkek
27.09.2011	09.08.2021	118	9,833333333	Erkek
22.09.2011	05.03.2021	113	9,416666667	Erkek
15.08.2009	06.07.2020	130	10,833333333	Erkek
04.07.2012	01.02.2022	114	9,5	Erkek
07.07.2014	12.10.2021	87	7,25	Erkek
14.08.2013	07.09.2021	96	8	Erkek

Çalışmamızın veri setini oluşturan bireylerden 276 erkek hastanın ortalama yaşı 10,94, 346 kadın hastanın ortalama yaşı ise 11,1'dir. Hasta kayıtlarına dair bilgiler Tablo 4.2'de sunulmuştur.

Tablo 4.2 Toplam Hasta Sayısı ve Yaş Ortalaması

	Erkek Hasta Sayısı	Kadın Hasta Sayısı
	276	346
Ortalama Yaş	10,94	11,1

4.2 Performans Metrikleri

Çalışmamızda önerilen yöntemlerin performans analizi için dikkate alınan metrikler bu bölümde sunulmaktadır.

4.2.1 Standart Sapma (Standard Deviation-SD)

Standart sapma, belirli bir değer kümesindeki dağılım veya varyasyonun hesaplanmasını temsil etmektedir.¹⁹⁴

Minimum standart sapma, değerlerin kümenin ortalamasına yakın olma eğiliminde olduğunu belirtirken, değerlerin geniş aralıkta olması durumunda standart sapmasının hesaplanmasında denklem.9'da gösterildiği gibi maksimum standart sapma kullanılmaktadır.

$$\text{Denklem.9: } \sigma = \frac{\sqrt{\sum(x_i - \mu)^2}}{N}$$

Denklem.9'da σ değeri standart sapmayı, N değeri hasta popülasyonun büyüklüğünü, μ değeri popülasyonun ortalamasını ve x_i değeri popülasyondaki bireysel değeri temsil etmektedir.

4.2.2 Ortalama Mutlak Hata (MAE)

MAE, regresyon modelleri ile kullanılan bir değerlendirme metriğidir. Tahmin edilen değerler ile gerçek değerler arasındaki farkın hesaplanmasıdır.¹⁹⁴ Test seti üzerinde uygulanan modelin MAE değeri, yani test seti üzerinde bireysel tahmin hatalarına karşılık gelen mutlak değerlerin ortalaması denklem.10 gösterilmektedir.

$$\text{Denklem.10: MAE} = \frac{\sum_{i=1}^n |\text{tahmin edilen deęerler} - \text{gerçek deęerler}|}{n}$$

Denklem.10'da n deęeri, toplam veri kümesini temsil etmektedir.

4.2.3 Ortalama Kare Hatası (MSE)

MSE regresyon kaybının hesaplanmasında kullanılan fonksiyondur. Bütün veri kümesindeki örnek başına ortalama kare kaybının hesaplanmasıdır.¹⁹⁴ Denklem.11 ile regresyon çizgisi ve regresyon noktalarını yakınlığı hesaplanmaktadır.

$$\text{Denklem.11:MSE} = \frac{1}{n} \sum_{i=1}^n (\text{gözlemlenen deęerler} - \text{tahmin edilen deęerler})$$

4.2.4 Kök Ortalama Kare Hatası (RMSE)

RMSE deęeri ile yalnızca belirli deęişkenler için çeşitli modellerin model konfigürasyonlarını veya tahmin hatalarını karşılaştıran ideal doğruluk hesaplaması olarak ifade edilmektedir. Denklem.13 ile verilmektedir.

$$\text{Denklem.13: RMSE} = \frac{\sqrt{\sum_{i=1}^N (\text{gerçek gözlem zaman serisi} - \text{tahmini zaman serisi})^2}}{N}$$

4.2.5 Determinasyon Katsayısı (R²)

R² regresyon tahminlerinin gerçek veri noktalarına olan uygunluk derecesinin istatistiksel hesaplamasıdır. İstatistikte goodness of fit olarak da ifade edilen ve önerilen modelin regresyon çizgisine uyum performansının deęerlendirildięi bir hesaplamadır. R² deęerinin 1'e eşit olması, regresyon tahminlerinin gerçekte karşılık gelen verilere mükemmel bir şekilde uyduğunu göstermektedir.¹⁹⁴ R² deęeri denklem.12 ile hesaplanmaktadır.

$$\text{Denklem.12: R}^2 = 1 - \frac{\text{Artık kareler toplamı}}{\text{Toplam kareler toplamı}}$$


4.3 Performans Analizi

Çalışmamızda önerilen sistemin performansı, kodun uygulanması sırasında hesaplanan MSE, MAE, RMSE ve R² deęerine göre analiz edilmektedir. Bir sistemin etkinlięinin ölçütü, maksimum tahmin oranı ve minimum hata oranı göstermesiyle belirlenmektedir. Bu anlamda maksimum R² puanı önerilen sistemin etkinlięini

belirlemektedir. Bu çalışmada önerilen sistemin MSE değeri 0,00027, MAE değeri 0,0079, RMSE değeri 0,0888 ve R^2 puanı 0,999 olarak tespit edilmiştir. Bulgular, Tablo 4.3'te gösterilmektedir. Ayrıca, tahmin edilen değerler ve gerçek değerlerin karşılaştırmalı olarak analizi grafik olarak Şekil 4.2'de gösterilmektedir.

Tablo 4.3 Çalışmamızda kullanılan sistemin değerlendirilen performans metriklerine göre bulguları

MSE	0,0002
MAE	0,0079
RMSE	0,0888
R^2	0,9999



Şekil 4.2 Tahmin edilen ve gerçek değerlerin karşılaştırmalı olarak analizini gösteren grafik

5. TARTIŞMA

Yaşayan veya ölü bireylerin yaş tahmini adli diş hekimliğinde önemli rol oynamaktadır. Kitlesele afet durumlarında, organize suçlarda, istismar olgularında kimlik tespiti yapılabilmesi için şüpheli ve mağdurların yaşlarının belirlenmesine ihtiyaç duyulmaktadır.¹⁹⁵ Kimliği belirlenemeyen cesetlerin varlığında kimlik tespiti ve kayıp diğer bireylerle karşılaştırılması noktasında yaş tespiti adli bilim mensuplarına değerli bilgiler sunmaktadır. Ek olarak bir bireyin yaşı, istismar, cezai sorumluluk, evlat edinme, iltica, kimlik ve doğum belgelerinin eksik olduğu durumlarda bilgi sağlanması konusunda da önemlidir.¹⁹⁶ Tıp ve diş hekimliği alanlarında ise teşhis ve tedavi süreçlerinin planlanması açısından ortodontist ve pediatristler için bireyin yaşının bilinmesi çok önemlidir. Bireyin yaşı, büyüme ataklarının zamanı ve gelecekteki tahmini büyüme hızına ve yönüne ışık tutmaktadır.¹⁹⁷

Adli bilimlerde yaş tahmini alanında en sık başvuru alan doku dişlerdir. Diş dokuları, özellikle mine dokusu, yapısal bileşimleri nedeniyle iskeletin en dayanıklı parçasıdır. Yüksek sıcaklıklar gibi çeşitli zor koşullara dayanıklıdır. Dolayısıyla binlerce yıl bozunmadan kalabilir. Ayrıca diş gelişimi hem çevresel hem de genetik faktörler tarafından yönlendirilmesine rağmen, diş dokularının mineralizasyonu kemik dokularına kıyasla bu faktörlerden daha az etkilenmektedir. Tüm bu durumlar diş dokularının kronolojik yaş noktasında gelişimin iyi bir göstergesi olarak görülmesine neden olmaktadır.^{2,198}

Diş yaşını tahmin etmek için literatürde birçok farklı metot geliştirilmiştir. Diş yaşını tahmin etmeye yönelik klasik radyolojik metotlar, daimi dişlerin mineralizasyon sürecinin radyomorfolojik veya radyometrik ölçümleriyle manuel olarak uygulanmaktadır.^{196,199}

Adli bilimler kapsamında bireyin yaşının belirlenebilmesinin önemi göz önüne alındığında, kullanılacak metodun güvenilir ve doğru sonuçlar sunması gerekmektedir. Bu doğruluk yüzdesinin yüksek olması, diş yaşı ve kronolojik yaş arasındaki ortalama farkın mümkün olduğu kadar az olması anlamına gelmektedir. Bu hususta doğru bir yaş tahmini gerçekleştirilebilmesi için, büyüme sürecini mümkün olduğunca takip

eden, yeterli ve arařtırmacılar tarafından kolayca ayırt edilebilecek kadar yeterince farklılařtırılmıř ařamalara sahip bir yöntemin seçilmesi büyük önem tařır.¹⁹⁹

5.1 Manuel Yař Tahmin Metotları

Literatürde, diř yařını tahmin etmek için en yaygın kullanılan metotlar, Demirjian metodu ve Willems metodudur. Demirjian metodu, diřlerin gelişim ařamalarının görselleřtirilmesi, tanımlayıcı kriterler, her ařamanın radyografik örnekleri ve sınırdaki ařamalarda karar vermek için seçim kurallarını ortaya koyan literatürdeki ilk metottur. Willems metodunda da Demirjian metoduna ait diř gelişim ařamaları ve tabloları ile diř yařı tahminleri gerekleřtirilmektedir.¹⁹⁹

Literatürde en sık kullanılan ve güvenilir metotlar olmasına karřın, bu metotlar da eřitli dezavantajları beraberinde tařımaktadır. Uygulaması zor ve uzun süre gerektiren eřitli tablolar ve gelişim evrelerini ieren řekiller iermektedirler. Bu durum, sürenin büyük önem tařıdığı adli olgularda ve büyük alıřma gruplarının deęerlendirildięi alıřmalarda kullanımını zorlařtırmaktadır. Ayrıca, deęerlendirilen popülasyonların etkilendięi genetik ve evresel faktörler neticesinde eksik veya fazla yař tahmini gerekleřtirilebilmektedir.²⁰⁰

Literatürde yapılan alıřmalarla etkinlięinin ortaya konmuř olması ve yař tahmini alanında en sık bařvurulan metotlar olması nedeniyle alıřmamızda, Demirjian ve Willems metodu ile aynı doęrultuda, sol yedi mandibular daimi diři ieren panoramik radyograflar deęerlendirilmiřtir.

5.1.1 Demirjian ve Willems metodunun etkinlięinin eřitli dünya popülasyonları üzerinde deęerlendirildięi alıřmalar

Literatürde Demirjian metodunun ve Willems metodunun popülasyonlar üzerinde etkinlięini inceleyen birok alıřma mevcuttur.^{196,201–215}

Mones ve arkadaşları tarafından, Mısırlı ocuklar üzerinde yapılan bir arařtırmada, Demirjian metodunun Mısırlı ocuklar için yař tahmini yapmada yetersiz olduęunu ve eřitli dönüşüm tabloları veya yeni denklemler geliřtirilmesi gerektięini ifade etmiřlerdir.²⁰²

Yang ve arkadaşları tarafından, Kuzey Çin Han popülasyonundan 603 kadın ve 646 erkek bireye ait panoramik radyograflar üzerinden Demirjian ve Willems metotlarının etkinliğinin değerlendirildiği bir çalışma gerçekleştirilmiştir. Çalışmanın bulgularına göre, Willems metodu kullanılarak yapılan hesaplamalarda, bu popülasyona ait bireylerin yaşları olduğundan daha az bulunduğu bildirilmiştir. Araştırmacılar inceledikleri popülasyon için Demirjian metodunun Willems metodundan daha etkin olduğunu bildirmişlerdir.²⁰²

Prasad ve Kala tarafından Hint popülasyonu üzerinde Demirjian ve Willems metotlarının etkinliğinin karşılaştırıldığı bir meta analiz çalışması yürütülmüştür. Çalışmanın bulgularına göre Hint popülasyonu için Demirjian metodu kullanılarak yapılan tahminlerde, tahmin edilen yaşın kronolojik yaştan daha fazla olduğu bildirilmiştir. Bu fazla tahmin miktarı, birkaç ay olarak hesaplanmıştır. Willems metodu kullanılarak yapılan tahminlerde ise, yaşın kronolojik yaşa kıyasla 30 ile 40 gün aralığında daha az tahmin edildiği bildirilmiştir. Araştırmacılar sonuç olarak, Hint popülasyonu için Willems metodu ile kronolojik yaşa daha yakın tahminler gerçekleştirilebileceğini, dolayısıyla yaş tahmini yapılırken bu metodun kullanımının daha uygun olacağını öne sürmüşlerdir.²⁰³

Literatürde Esan ve arkadaşları tarafından gerçekleştirilmiş bir başka meta-analiz çalışmasında Demirjian ve Willems metodunun çeşitli popülasyonlar üzerinde diş yaşı tahminindeki etkinliği değerlendirilmiştir. Bu çalışmada, Demirjian metodu ile yaş tahmini yapıldığında 3-15 yaş arasındaki erkek ve 4-16 yaş arasındaki kadın bireyde tahmin edilen yaşın kronolojik yaştan istatistiksel olarak anlamlı olduğundan fazla tahmin edildiği bildirilmiştir ($p < 0.05$). Araştırmacılar Willems metodu ile ilgili yaptıkları değerlendirmede, Demirjian metodunda görülen, yaşı olduğundan fazla tahmin etme durumunun her iki cinsiyet için de söz konusu olmadığını bildirmişlerdir. Araştırmacılar bu çalışmanın sonucu olarak, diş yaşı tahmininde en yüksek doğruluğu elde edebilmek için, evrensel bir standart veya diğer popülasyonlar üzerinde geliştirilmiş metotlar yerine incelenecek popülasyonlara özgü metotlar kullanılması gerektiğini önermişlerdir.²⁰⁴

5.1.2 Demirjian ve Willems metodunun etkinliđinin Türk popülasyonu üzerinde deđerlendirildiđi alıřmalar

Tun ve Koyutürk 2008 yılında, Demirjian metodunun kuzey Türk toplumundaki ocuklar için uygulanabilirliđini deđerlendirdikleri alıřmalarında yařları 4 ile 12 arasında deđiřen 419 bireye ait panoramik radyograflar deđerlendirilmiřtir. alıřmanın bulgularına gre Demirjian metodu kullanılarak yapılan deđerlendirilmelere gre diř yařı ile kronolojik yař arasında gcl bir korelasyon bildirmiřlerdir. Bu deđer kadınlar için $R^2= 0,77$, erkekler için ise $R^2= 0,78$ 'dir. kuzey Türk toplumundaki ocukların diř geliřiminin, Demirjian metodunun oluřturulduđu poplasyondaki ocuklarla karřılařtırıldıđında genel olarak ileri dzeyde olduđu bildirilmiřtir. alıřmanın bulgularına gre, erkek ve kadınlar için diř yařı ve kronolojik yař arasındaki ortalama fark sırasıyla 0,36 ile 1,43 ve 0,50-1,44 arasında deđiřmektedir ve Demirjian metodunun Türk ocukları için yařı olduđundan fazla tahmin ettiđi bildirilmiřtir.²⁰⁵ Liversidge ve arkadařları²⁰⁶, farklı poplasyonlar üzerinde Demirjian metodu kullanılarak diř yařı tahmini yapılan alıřmalardaki bulgularda Demirjian metodunun yařı olduđundan fazla tahmin etmesinin nedeninin son 25 yıldıki byme ve geliřimdeki pozitif sekler eđilimle aıklanabileceđini ne srmřlerdir. Arařtırmacılar Demirjian metodu ile Türk ocukları için yařın olduđundan fazla tahmin edilmesinin nedeninin aynı sebep ile aıklanabileceđini ifade etmiřlerdir.²⁰⁵

elikođlu ve arkadařları 2008 yılında Dođu blgesindeki Türk ocuklarında Demirjian metodunun uygulanabilirliđini arařtırdıkları alıřmalarında yařları 7 ile 15 arasında deđiřen 807 sađlıklı bireyin panoramik radyograflarını incelemiřlerdir. alıřmanın bulgularına gre kronolojik ve diř yařı arasındaki ortalama farkın kadınlarda 0,2 ile 1,9, erkeklerde 0,4 ile 1,3 arasında deđiřtiđini bildirilmiřtir. Arařtırmacılar, alıřmanın bulgularına gre Demirjian metoduyla tahmin edilen yař ile kronolojik yař arasındaki fark tm yař grupları için istatistiksel olarak farklı bulunduđunu bildirmiřlerdir. Arařtırmacılar Dođu blgesindeki Türk ocuklarının ileri bir diř geliřimi gsterdiklerini ve dolayısıyla Demirjian metodunun bu toplum için uygulanabilir olmadıđını ifade etmiřlerdir.²⁰⁷

Erdem ve arkadařlarının 2013 yılında, Trkiye'nin kuzeybatısında bulunan ocuklarda Demirjian metodunun geerliliđinin arařtırıldıđı alıřmalarında 5-13 yař

arasındaki 756 bireye ait panoramik radyografları değerlendirilmiştir. Çalışmanın bulgularına göre kuzeybatı Türk toplumundaki çocuklarda diş olgunlaşmasında gecikme olduğu ve Demirjian metodunun bu toplum için uygulanabilir olmadığı bildirilmiştir. Araştırmacılar Demirjian metoduna ait diş gelişim aşamaları ve skorlamayı referans alarak, değerlendirilen toplum için uyarlanmış yeni bir formül önermişlerdir. Araştırmacıların önerdikleri formüle göre yapılan değerlendirmelerde diş yaşı ve kronolojik yaş arasında istatistiksel olarak anlamlı bir fark bildirilmemiştir.²⁰⁸

Çelik ve arkadaşlarının, 2014 yılında güney bölgede yaşayan Türk alt popülasyonuna ait çocuklar için Demirjian metodunun uygulanabilirliğini araştırdıkları çalışmalarında yaşları 4 ile 18 arasında değişen 932 sağlıklı bireye ait panoramik radyograf değerlendirilmiştir. Araştırmacılar yaptıkları değerlendirmelere göre Demirjian metodunun çalışma popülasyonundaki 9-9,9 yaş ve 15-15,9 yaş grubundaki kadınlar ve 16-16,9 yaş grubundaki erkekler üzerinde uygulanabilir olduğunu bildirmişlerdir. Araştırmacılar diş gelişiminin ülkenin farklı bölgelerindeki bireyler için dahi farklılıklar gösterdiğini ve Demirjian metodunun, inceledikleri popülasyon için kullanılabilir olmadığını bildirmişlerdir.²⁰⁹

Güngör ve arkadaşları 2015 yılında, Demirjian metodunun güney Türkiye nüfusu için uygulanabilirliğini değerlendirdikleri çalışmalarında 10- 18 yaş arasındaki 535 bireyi değerlendirmişlerdir. Çalışmanın bulgularına göre diş yaşı ve kronolojik yaş arasındaki ortalama fark kadınlarda 0,02 ile 0,79 yıl, erkeklerde ise 0,04 ile 0,85 yıl arasında değişmektedir. Araştırmacılar Demirjian metodunun güney Türkiye nüfusu için tüm yaş gruplarına uygun olmadığını bildirmişlerdir. Çalışmada diş yaşının istatistiksel olarak kadınlarda 10 ve 11 yaş gruplarında anlamlı derecede fazla ve erkeklerde 13-15 yaş gruplarında ise anlamlı derecede düşük tahmin edildiği bildirilmiştir. Araştırmacılar güney Türkiye nüfusu için Demirjian metodunun kullanılmasının genel olarak uygun olduğunu ancak bazı yaş grupları için revizyona ihtiyaç duyulduğunu bildirmişlerdir.²¹⁰

Altunsoy ve arkadaşları 2015 yılında, yaşları 7 ile 16 arasında değişen 685 bireyi içeren bir veri seti ile Demirjian metodunun batı Türkiye nüfusu için geçerliliğini araştıran bir çalışma gerçekleştirmişlerdir. Çalışmanın bulgularına göre diş yaşı ve kronolojik yaş arasındaki farkın kadınlarda 0,28 ile 0,87 yıl, erkeklerde ise

0,10-0,76 yıl arasında deęiřtięi ve diř yařlarının istatistiksel olarak anlamlı bir řekilde fazla bulunduęu bildirilmiřtir. Arařtırmacılar, batı Trkiye nfusundaki bireylerde diř yařı tahmini iin Demirjian metodunun uygun olamadıęını bildirmiřlerdir. Arařtırmacılar ayrıca batı Trk nfusundaki bireylerin diř yařı olgunluęunun doęu, kuzeydoęu ve kuzey Trk nfusundaki bireylerdekinden daha dřk olduęunu bildirmiřlerdir.²¹¹

Ko ve arkadařları, 2015 yılında Willems, Nolla ve Londra atlası metotlarını kullanarak diř yařını tahmin etmek ve bu metotların doęruluęunu karřılařtırmak amacıyla bir alıřma gerekleřtirmiřlerdir. alıřma, yařları 6 ile 14 arasında deęiřen 919 bireye ait panoramik radyograf kullanılarak gerekleřtirilmiřtir. alıřmanın bulgularına gre, MAE deęeri Londra Atlası metodunda 0,83, Willems metodunda 0,80 ve Nolla metodunda ise 0,89 olarak bulunmuřtur. Arařtırmacılar, alıřmanın bulgularına gre  metodun da istatistiksel olarak kabul edilebilecek derecede doęruluk gsterdięini, doęu Trk nfusuna ait bireylerde diř yařı tahmini iin en uygun metodun, en az MAE ile Willems metodu olduęunu bildirmiřlerdir. Arařtırmacılar ayrıca uygulama kolaylıęı ve karřılařtırılabilirlik aısından Londra atlası metodunun da tercih edilebileceęini bildirmiřlerdir.²¹²

Onat Altan ve arkadařlarının, 2016 yılında Willems metodunun gney blgedeki Trk ocuklarının diř yařlarının deęerlendirmesinde uygulanabilirlięi ve doęruluęunu arařtırdıkları alıřmalarında yařları 5-15 yař arasında deęiřen 756 bireye ait panoramik radyograf deęerlendirilmiřtir. alıřmanın veri setini oluřturan bireyler kronolojik yařlarına gre kadın ve erkekler iin 10'ar gruba ayrılmıřtır. alıřmanın bulgularına gre, kronolojik yař ve diř yařı arasında kadınlar iin $R^2=0,946$ ve erkekler iin $R^2=0,940$ deęeri ile gl bir korelasyon grldę bildirilmiřtir. Arařtırmacılar Willems metodunun kadınlar iin daha doęru sonu verdięini ancak karıřık diřlenme dneminde her iki cinsiyet iin daha dřk doęruluk gsterdięini bildirilmiřlerdir. Arařtırmacılar, Willems metodunun uygulanmasıyla diř yařı ve kronolojik yař arasındaki uyumun kadınlarda 5-5,99, 6-6,99, 12-12,99 ve 14-14,99 yař gruplarında, erkekler iin ise 5-5,99, 13-13,99 ve 14-14,99 yař gruplarında tutarlı olduęunu ne srmřlerdir. Bu alıřmanın bulgularına gre arařtırmacılar Willems metodunun kadınlar iin erkeklere gre daha doęru sonular verdięini ve alıřmalarının ileride yapılacak alıřmalara katkıda bulunabileceęini bildirmiřlerdir.²¹³

Nur ve arkadaşları, 2019 yılında kuzeydoğu Türk nüfusu için Demirjian ve Nolla metotlarının uygulanabilirliğini araştırdıkları çalışmalarında, yaşları 5 ile 15,9 arasında değişen 673 bireye ait panoramik radyograf değerlendirilmiştir. Çalışmanın bulgularına göre, hem Demirjian metodu (kadınlar ve erkekler için; sırasıyla $R^2=0,931$, $R^2=0,913$) hem de Nolla metodu (kadınlar ve erkekler için; sırasıyla $R^2=0,928$, $R^2=0,914$) için kronolojik yaş ve diş yaşı arasında güçlü bir doğrusal korelasyon olduğu bildirilmiştir. Araştırmacılar, Demirjian ve Nolla metotları için kronolojik yaş ve diş yaşı arasındaki ortalama farkı, toplam çalışma örneklemi için sırasıyla +0,86 ve -0,54 yıl olarak bildirmişlerdir. Çalışmanın bulgularına göre araştırmacılar, Nolla metodunun Türk popülasyonu için daha doğru sonuç verdiği bildirmişlerdir.²¹⁴

Apaydın ve Yaşar, 2018 yılında Demirjian, Willems ve Cameriere metodunun Türk popülasyonu için doğruluğunu araştıran bir çalışma gerçekleştirmişlerdir. Çalışma için yaşları 5 ile 15,9 arasında değişen 330 bireye ait panoramik radyograf değerlendirilmiştir. Çalışmanın bulgularına göre Demirjian metodunun yaşı olduğundan 0,304 yıl fazla, Willems metodunun 0,06 yıl daha az ve Cameriere metodunun ise 0,58 yıl daha az tahmin ettiği bildirilmiştir. Araştırmacılar, Willems metodu ile diş yaşı ile kronolojik yaş arasında istatistiksel olarak anlamlı bir fark bulunmadığını ve en doğru sonuçların bu metot ile elde edildiğini bildirmişlerdir. Adli bilimlerde diş yaşı ve kronolojik yaş arasındaki kabul edilebilir yaş farkın çocuklar için ergenliğe kadar ± 1.00 yıl olduğu bildirilmiştir. Bu yaş tahmini yapılırken Willems ve Demirjian metotlarının 5 ile 15 yaş arası Türk çocukları için kullanılabilir olduğunu bildirmişlerdir.¹⁹⁶

Özveren ve arkadaşlarının 2019 yılında gerçekleştirdikleri çalışmada Willems ve Cameriere metotlarının Türk çocukları için uygulanabilirliği araştırılmıştır. Bunun için yaşları 6 ile 15 arasında değişen 636 bireye ait panoramik radyograf değerlendirilmiştir. Çalışmanın bulgularına göre, farklı yaş gruplarında Cameriere metodu ile yapılan değerlendirmelere göre kronolojik yaş ve diş yaşı arasındaki ortalama fark kadınlar için 1,00 ila 0,21 yıl ve erkekler için 0,86 ila 0,41 yıl arasında değişirken, Willems metoduyla yapılan değerlendirmelere göre, erkekler için 0,26 ile 0,71 yıl, kadınlar için 0,19 ile 0,76 yıl arasında değişmektedir. Cameriere metodunun, Willems metoduna göre daha yüksek bir doğruluk yüzdesi (sırasıyla erkekler ve kadınlar için %84,6 ve %77,3) gösterdiği bildirilmiştir. Araştırmacılar çalışmanın

sonucunda her iki metodun da Türk popülasyonu için uygulanabilir olduğunu bildirmişlerdir.²¹⁵

5.2 Yapay Zeka Algoritmalarına Dayalı Yaş Tahmin Çalışmaları

Literatürdeki klasik metotlar, çok sayıda katılımcının dahil olduğu büyük veri kümeleri incelenerek ortaya konmuştur. Ancak bu metotlar, sonuçların çoğunlukla popülasyonlara özgü olması ve gözlemci öznelliğinden etkilenen zaman alıcı manuel işlemlere dayanması gibi birtakım dezavantajlara sahiptir.^{6,200}

Klasik manuel radyolojik diş yaşı tahmin metotlarının bir diğer dezavantajı da bu metotların büyüme sürecini mümkün olduğu kadar yakından takip etmeye yeterli sayıda aşama içermemesidir. Ayrıca araştırmacılar tarafından gelişim aşaması olarak yeterince farklılaşmamış dişlerin ayırt edilmesine olanak sağlayacak yöntemin seçilmesindeki zorluk da bir başka dezavantaj olarak öne sürülebilir.⁶

Son yıllarda, manuel metotlardaki dezavantajların üstesinden gelmek ve yaş tahminini otomatikleştirmek amacıyla yapay zeka algoritmalarına dayanan çalışmalar gerçekleştirilmiştir. Yapay zeka algoritmalarına dayalı sistemler, problemlerin çözümünde işlem süresini kısaltmanın yanı sıra, tutarlı ve tekrarlanabilir sonuçlar sunmaktadır. Bu sistemler, insan gözü ile fark edilemeyecek ve manuel hesaplama için mümkün olmayan öznelikleri tespit edebilme yeteneğine sahip sistemlerdir. Ayrıca tespit edilen bu özneliklerin birbirleriyle olan ilişkisini keşfetme konusunda belirgin avantaja sahiptir. Bu sistemlerin kullanımıyla, çok sayıda farklı ve doğrusal olmayan özneliklerin keşfi, daha iyi bir tahmin ve daha düşük hata değerleri elde edilmesini sağlar.⁵

Literatürdeki yapay zeka algoritmalarına dayanan çalışmalar metodoloji olarak, makine öğrenmesi, derin öğrenme veya iki yaklaşımın da beraber kullanıldığı çalışmalar olarak karşımıza çıkmaktadır. Yaş tahmini üzerine gerçekleştirilmiş mevcut çalışmaların farklı amaçları vardır. Bu çalışmalar, sayısal yaş regresyonu amacıyla yapılan çalışmalar, dişlerin evrelendirilmesi amacıyla yapılan çalışmalar, yaş grubu sınıflandırması amacıyla yapılan çalışmalar ve yasal yaş sınıflandırması amacıyla yapılan çalışmalar olarak Tablo 5.1'deki gibi gruplandırılabilir.¹⁹⁸

Tablo 5.1 Literatürde yapay zeka algoritmaları kullanılarak gerçekleştirilmiş çalışmalar

Çalışmalar	Amaç	Metodoloji	Kullanılan ağ mimarisi
Galibourg ve arkadaşları ¹⁹⁹	Sayısal Yaş Regresyonu	Makine Öğrenimi	<ul style="list-style-type: none">· RF· Destek vektör makinesi (Support Vector Machine-SVM)· Karar ağacı (Decision Tree-DT)· Bayesian ridge regresyon (Bayesian Ridge Regression-BRR)· K-en yakın komşu (K-Nearest Neighbors-KNN)· AdaBoost (ADAB)· Polinom Regresyon (POLYREG)· Çok katmanlı algılayıcı (Multi-Layer Perceptron-MLP)· Yığılma (STACK)· Oylama (VOTE)
Tao ve arkadaşları ²¹⁶	Sayısal Yaş Regresyonu	Makine Öğrenimi	<ul style="list-style-type: none">· MLP
Shen ve arkadaşları ²¹⁷	Sayısal Yaş Regresyonu	Makine Öğrenimi	<ul style="list-style-type: none">· RF· SVM· Doğrusal regresyon (Lineer- Regression-LR)
De Tobel ve arkadaşları ²¹⁸	Dişlerin evrelendirilmesi	Derin Öğrenme	<ul style="list-style-type: none">· AlexNet
Boedi ve arkadaşları ²¹⁹	Dişlerin evrelendirilmesi	Derin Öğrenme	<ul style="list-style-type: none">· DenseNet201
Banar ve arkadaşları ²²⁰	Dişlerin evrelendirilmesi	Derin Öğrenme	<ul style="list-style-type: none">· YOLO benzeri bir konvolüsyonel Sinir Ağı + U-Net + DenseNet201
Kim ve arkadaşları ²²¹	Yaş Grubu Sınıflandırılması	Derin Öğrenme	<ul style="list-style-type: none">· ResNet152
Guo ve arkadaşları ²²²	Yaş Grubu Sınıflandırılması	Derin Öğrenme	<ul style="list-style-type: none">· SE-ResNet101
Čular ve arkadaşları ²²³	Sayısal Yaş Regresyonu	Derin Öğrenme	<ul style="list-style-type: none">· Aktif Şekil Modeli (AŞM)· Aktif Görünüş Modeli (AGM) ve Radial Basis Network
De Back ve arkadaşları ²²⁴	Sayısal Yaş Regresyonu	Derin Öğrenme	<ul style="list-style-type: none">· Bayesian Konvolüsyonel Sinir Ağları
Vila-Blanco ve arkadaşları ⁶	Sayısal Yaş Regresyonu	Derin Öğrenme	<ul style="list-style-type: none">· DANet ve DASNet
Wallraff ve arkadaşları ²²⁵	Sayısal Yaş Regresyonu	Derin Öğrenme	<ul style="list-style-type: none">· ResNet18

Tablo 5.1 devam Literatürde yapay zeka algoritmaları kullanılarak gerçekleştirilmiş çalışmalar

Vila-Blanco ve arkadaşları ¹⁹⁸	Sayısal Yaş Regresyonu	Derin Öğrenme	· Rotated R-CNN
Milošević ve arkadaşları ⁵	Sayısal Yaş Regresyonu	Derin Öğrenme	· Transfer Öğrenme (DenseNet201, InceptionResNetV2, ResNet50, VGG16, VGG19)
Sharifonnasabi ve arkadaşları ²²⁶	Sayısal Yaş Regresyonu	Derin Öğrenme ve Makine Öğrenmesi	· Konvolüsyonel Sinir Ağları ve KNN ile birlikte oluşturulmuş hibrit bir model
Bizim Çalışmamız	Sayısal Yaş Regresyonu	Derin Öğrenme ve Makine Öğrenmesi	Öznitelik Çıkarımı için 1D-CNN ve 2D-CNN Regresyon için Modifiye Genetik Rastgele Orman

5.2.1 Makine Öğrenimine Dayalı Çalışmalar

Literatürde son yıllarda gerçekleştirilmiş çalışmalarla ortaya konan makine öğrenimine dayalı teknikler, kemik yaşı tahmini konusunda adli bilim uzmanlarına memnuniyet verici bir destek sağlamaktadır. Makine öğrenimi teknikleri ile diş yaşı tahmini noktasında da çalışmalar son yıllarda ivme kazanmıştır.²¹⁷

Yapay zekanın bir alt dalı olan makine öğrenimi ile referans alınan metotlarla aynı açıklama sistemini korunurken, uygunluk tablolarına ihtiyaç duymadan sistemdeki karmaşıklığı yakalayabilen modelleri formüle etmek için bir çözüm sunan algoritmalar elde edilmektedir.¹⁹⁹

Makine öğrenimi ile yaş tahmini alanında gerçekleştirilen çalışmalarda diş yaşının klasik manuel metotlara kıyasla daha hızlı ve daha verimli bir biçimde tahmin edilebileceği öne sürülmüştür. Bu durum, toplu afetler gibi hızlı ve doğru tespitlerin gerçekleştirilmesi gereken durumlarda kritik bir önem arz etmektedir.²¹⁷

Galibourg ve arkadaşları¹⁹⁹ makine öğrenimi algoritmaları kullanarak diş yaşını tahmin etmek ve bu algoritmaların tahmin performansını sistemin eğitilmesinde açıklayıcı sistem olarak referans aldıkları Demirjian ve Willems metotlarıyla karşılaştırmak amacıyla bir çalışma gerçekleştirmişlerdir. Çalışmaya Fransız popülasyonundan yaşları 2 ile 24 arasında değişen sağlıklı 1734 kadın ve 1871 erkek bireye ait 3605 panoramik radyograf dahil edilmiştir. Çalışmanın veri setini oluşturan bireyler 16 yaş altındaki bireyler ve 24 yaş altındaki bireyler olarak iki gruba ayrılmıştır. 16 yaş altındaki bireylerden oluşan grupta Demirjian ve Willems metodu

ile, 24 yaş altındaki bireylerden oluşan grupta ise Demirjian metodu ile yaş tahmini manuel olarak gerçekleştirilmiştir. Çalışmada bireyin diş yaşını tahmini regresyon problemi olarak ele alınmıştır. Bunun için doğru algoritmik süreçler geliştirmek adına güçlü bir aracı temsil edebilen, yapay zekanın bir parçası olan makine öğrenimi algoritmaları ile yaş tahmini gerçekleştirilmiştir.

Çalışmanın metodolojisinde, makine öğrenimi algoritmalarının eğitimi cinsiyet ve ana gözlemci tarafından sol yedi mandibular daimi dişe ve tüm üçüncü azı dişlerine tahsis edilen aşamalar ile gerçekleştirilmiştir. Açıklayıcı sistem olarak Demirjian ve Willems metotları referans alınmıştır. Çalışmada hedeflenen değer kronolojik yaştır. Bunun için denetimli regresyon algoritmalarından; RF, SVM, DT, BRR, KNN, ADAB, POLYREG ve MLP yöntemleri ile ayrı ayrı testler gerçekleştirilmiştir. Bahsedilen farklı makine öğrenimi tekniklerini birleştirmenin faydasını test etmek için STACK ve VOTE yöntemleri de ayrıca test edilmiştir.

Çalışmada kullanılan referans metotlar ve makine öğrenimi algoritmalarının performansı R^2 , MAE, RMSE, SD ile değerlendirilmiştir. Araştırmacılar, makine öğrenimi yöntemleri ile yaş tahmininin, çocukluktan erken yetişkinliğe kadar radyografik diş evrelemesine dayalı manuel metotlarından daha iyi performans gösterdiğini bildirmişlerdir. Çalışmamızda, 15 yaşından küçük bireylere odaklandığından, Galibourg ve arkadaşlarının¹⁹⁹ çalışmasının 16 yaşından küçük bireylerden oluşan grubuna ait bulgular ile kıyaslama yapılmıştır. Çalışmaya ait bulgular ve çalışmamızın bulguları Tablo 5.2'de sunulmuştur.

Tablo 5.2 Galibourg ve arkadaşlarının¹⁹⁹ çalışmasına ait bulgular ve çalışmamızın bulguları

Metotlar	SD	MAE	MSE	RMSE	R²
Demirjian	-0.705	1,108	1,981	1,406	0,816
Willems	-0,220	0,928	1,418	1,190	0,868
BRR	-0,002	0,812	1,030	1,014	0,904
SVM	0,016	0,729	0,901	0,949	0,916
DT	-0,012	0,758	0,973	0,985	0,910
RF	-0,007	0,731	0,885	0,940	0,918
KNN	0,009	0,738	0,921	0,959	0,915
MLP	-0,041	0,742	0,907	0,952	0,916
POLYREG	-0,008	0,735	0,913	0,955	0,915
ADAB	-0,025	0,796	1.001	1,000	0,907
STACK	-0,013	0,733	0,904	0,950	0,916
VOTE	0,068	0,770	0,995	0,984	0,908
Bizim çalışmamız	0,0004	0,0079	0,00027	0,0888	0,9999

Galibourg ve arkadaşlarının çalışması, tamamen makine öğrenimine dayanan bir metodoloji ile gerçekleştirilmiştir. Araştırmacıların çalışmalarında ortaya koydukları makine öğrenimi sisteminin eğitiminde açıklayıcı sistem olarak Demirjian ve Willems metotları referans alınmıştır. Bu metotlar ile yaş tahmini gerçekleştirilirken sol yedi mandibular daimi dişe odaklanılmaktadır.

Çalışmamız, sol yedi mandibular daimi dişi içeren panoramik radyograf kesitleri üzerinden herhangi bir açıklayıcı sistem olmadan tamamen otomatik bir biçimde yaş tahmini gerçekleştirilmek amacı ile gerçekleştirilmiştir. Çalışmamızın veri setini oluşturan radyograflar ve hasta kayıtlarından derin öğrenme metotlarından 1D-DCNN ve 2D-DCNN mimarisi kullanılarak öznitelik çıkarımı yapılmıştır. Regresyon adımı ise RF ve GA metotları modifiye edilerek birleştirilmiş ve yaş tahmini gerçekleştirilmiştir.

Çalışmamız, Galibourg ve arkadaşlarının¹⁹⁹ çalışması ile performans yönünden kıyaslandığında, çalışmamızın, ilgili çalışmada manuel olarak gerçekleştirilmiş tahminlerden ve değerlendirilen tüm makine öğrenimi yaklaşımlarından daha üstün bir performansa sahip olduğu gözlenmiştir. Ayrıca çalışmamızda kullanılan sistem ile MAE değerinin belirgin ölçüde azaldığı tespit edilmiştir. MAE değerinin az olmasının sebebinin, çalışmamızın öznitelik çıkarımı adımı derin öğrenme algoritmalarının kullanılmasına bağlı olarak insan gözü ile tespit edilemeyecek ve yaş ile ilişkili çeşitli göstergelerin derin öğrenme algoritmaları tarafından algılanması ve dolayısıyla MG-RF algoritmasına daha fazla bilgi aktarımı sayesinde olabileceği düşünülmektedir. MG-RF adımı RF algoritması, metodoloji olarak tek tek ağaçlar arasındaki benzerliği azaltmaktadır. Bu nedenle ağaç oluşturma sürecindeki her adımda, giriş özniteliklerinin rastgele bir alt kümesinden ayrılma noktasını seçerek nihai modelin sağlamlığını artırdığı düşünülmektedir. Ayrıca çalışmamızda derin öğrenme süreçlerini takiben makine öğrenmesi tekniklerinin kullanılmasıyla dört ayrı yapay zeka tekniği bir arada sisteme entegre edilmiştir. Birçok tekniğin bir arada kullanılması ile sistemin hata oranında belirgin bir azalma ve performansında belirgin bir artış düşünülmektedir.

Çalışmamızda yaş tahmini, herhangi bir açıklayıcı referans sistem kullanmadan tamamen otomatik bir biçimde gerçekleştirilmektedir. Çalışmamızın yaş tahmini görevini otomatikleştirmesi sayesinde insan yorumuna maruziyet ve insan

gözclemcilerin öznelliđi dezavantajını ortadan kaldırması, alıřmamızın bir avantajı olarak öne sürülebilir. Ayrıca açıklayıcı sistem kullanılmaması ve otomatik bir yöntem olması, alıřmamızı kullanımı kolay, hızlı ve tekrarlanabilir yapmaktadır.

Tao ve arkadaşları²¹⁶ 2020 yılında yaşları 11 ile 19 arasında deđiřen 787 erkek ve 849 kadın bireye ait 1636 panoramik radyograftan oluşan bir veri kümesi ile gerçekleřtirdikleri alıřmalarında, diř yaşı tahminindeki dođruluđu artırmak amacıyla makine öđrenimine dayalı bir yaklaşım önermiřlerdir. alıřmada diř yaşı tahmini bir regresyon problemi olarak ele alınmıřtır.

alıřmanın metodolojisinde ilk olarak Demirjian metodu ve Willems metodu ile manuel ölçümler gerçekleştirilmiřtir. Hastaların gerçek yaşlarının da sisteme kaydedilmesiyle öznitelikler belirlenmiřtir. Ardından bu öznitelikler ile makine öđrenimi yaklaşımlarından ileri beslemeli bir yapay sinir ađı olan MLP algoritması eđitilmiř ve deneyler gerçekleştirilmiřtir. alıřmada önerilen sistemin performansı MAE, MSE, RMSE metrikleri ile deđerlendirilmiřtir. alıřmada önerilen sistemin tüm performans metrikleri açısından referans alınan manuel metotlardan daha iyi performans gösterdiđi bildirilmiřtir.²¹⁶ alıřmaya ait bulgular ve alıřmamızın bulguları Tablo 5.3'te sunulmuřtur.

Tablo 5.3 Tao ve arkadaşlarının²¹⁶ alıřmasına ait bulgular ve alıřmamızın bulgularıyla kıyaslaması

Erkek	RMSE	MSE	MAE	Kadın	RMSE	MSE	MAE
Demirjian Metodu	1,596	2,548	1,307	Demirjian Metodu	1,677	2,812	1,364
Willems Metodu	1,602	2,556	1,291	Willems Metodu	1,788	3,196	1,407
MLP	1,332	1,775	0,990	MLP	1,617	2,616	1,261
Bizim alıřmamız	0,8888	0,00027	0,0079		0,8888	0,00027	0,0079

alıřmamız, performansın deđerlendirildiđi RMSE, MSE ve MAE metriklerine göre, Tao ve arkadaşlarının alıřmasındaki hem kadın hem de erkek grupları için elde edilen bulgulardan belirgin olarak daha iyi performans göstermektedir. Bu bulgunun sebebi, alıřmamızın odaklandıđı grubun daha genç bireylerden oluşması (6-15 yaş) ve bu bireylerin yaş dađılımındaki farklılıklardan kaynaklanıyor olabilir. Büyüme ve gelişime dair yaş göstergelerinin yaş ile birlikte

azalması nedeniyle yaş tahmini alanındaki çalışmalarda genç çalışma popülasyonları ile daha doğru sonuçlar elde edilmesi bilinen bir gerçektir.⁵

Çalışmamızda derin öğrenme metotlarının ve makine öğrenmesi metotlarının bir arada kullanılmasının performansı belirgin ölçüde artırdığı düşünülmektedir. Derin öğrenme tekniklerinin insan gözü ile fark edilemeyecek bazı bağlantıları kurabilme avantajı sayesinde manuel olarak hesaplanması mümkün olmayan yaş göstergelerinin çalışmamızdaki sisteme dahil edilmiş olduğu düşünülmektedir. Bu durumun çalışmamızdaki sistemin başarımındaki artışın kaynağı olabileceği öne sürülebilir. Ayrıca çalışmamız, herhangi bir açıklayıcı sisteme bağlı olmayan otomatik bir sistemdir. Bu nedenle çalışmamız, hızlı, tekrarlanabilir ve insan yorumuna daha az açık bir sistem olmasının avantajlarını taşımaktadır.

Shen ve arkadaşları²¹⁷, 2021 yılında yaptıkları çalışmalarında yaş tahmini yapmak için çeşitli makine öğrenimi sistemleri ile testler gerçekleştirmişlerdir. Çalışmanın veri setini 5 ile 13 yaş arasındaki 356 kadın ve 392 erkek bireye ait toplam 748 panoramik radyograf oluşturmaktadır. Çalışmada metodoloji olarak makine öğrenimi yöntemlerinden RF, SVM ve doğrusal LR kullanılmıştır. Bu makine öğrenimi modelleri, açıklayıcı sistem olarak manuel gerçekleştirilmiş Cameriere metodu ve cinsiyet bilgisi ile eğitilmiştir. Hedef değer kronolojik yaş olarak belirlenmiştir. Çalışmada önerilen sistemlerin yaş tahmin doğruluğunun performansı R^2 , ME, RMSE, MSE ve MAE ile değerlendirilmiştir. Bulgular sistemin eğitiminde kullanılan Cameriere metodunun Avrupa formülü ve Çin formülü ile karşılaştırılmıştır. Çalışmaya ait bulgular ve çalışmamızın bulguları Tablo 5.4'teki gibidir.²¹⁷

Tablo 5.4 Shen ve arkadaşlarının²¹⁷ çalışmasına ait bulgular ve çalışmamızın bulgularıyla kıyaslaması

Metotlar	MAE	MSE	RMSE	R2
LR	0,553	0,488	0,698	0,909
SVM	0,489	0,392	0,625	0,925
RF	0,495	0,389	0,623	0,928
Cameriere metodu (Avrupa Formülü)	0,846	0,755	0,869	-
Cameriere metodu (Çin Formülü)	0,812	0,89	0,943	-
Bizim Çalışmamız	0,0079	0,0002	0,0888	0,9999

Çalışmada önerilen sistemlerin performansı R^2 değeri yönünden çalışmamızla benzer şekilde yüksek bir performans elde edildiği görülmüştür. Ancak değerlendirilen diğer performans metrikleri yönünden Shen ve arkadaşlarının önerdiği sistemlerin hata oranları çalışmamıza göre belirgin düzeyde fazla olduğu dikkat çekmektedir. Bu bulgunun nedeninin, çalışmamızın öznitelik çıkarımı adımında derin konvolüsyonel sinir ağlarının kullanılması ile insan gözü ile tespit edilemeyecek bazı yaş göstergelerinin sisteme dahil olması ve birçok tekniğin bir arada kullanılması sayesinde olabileceği düşünülmektedir.

5.2.2 Derin Öğrenmeye Dayalı Çalışmalar

Son yıllarda, yapay zekanın bir alt dalı olan derin öğrenme teknikleri ile bilgisayarlı görme, konuşma tanıma, doğal dil işleme ve biyoinformatik gibi alanlarda çığır açan bulgular elde edilmiştir. Ayrıca derin öğrenme, tıp alanındaki çalışmalarda da sıklıkla yararlanılan bir teknik haline gelmiştir. Özellikle konvolüsyonel sinir ağları ve derin konvolüsyonel sinir ağları en sık başvurulan metodolojiler olarak karşımıza çıkmaktadır.²²²

Derin öğrenme tekniklerine dayanan sistemler problemlerin çözümünde işlem süresini kısaltmakla beraber, tekrarlanabilir tutarlı sonuçlar ortaya koymaktadır. Derin öğrenme algoritmaları ile önerilen sistemler, derin öğrenmenin insan gözü ile tespit edilemeyecek bazı özellikleri ve bu özelliklerin arasındaki ilişkiyi tespit edebilmesi nedeniyle çok yüksek performans sunmaktadır. Ancak derin öğrenme, yorumlanabilirlik açısından dezavantaj taşımaktadır. Bu dezavantajın üstesinden gelmek ve yorumlanabilirliği geliştirmek için bazı araştırmacılar ısı haritaları gibi bazı görselleştirme tekniklerine başvurulsa da temelde çalışma bulgularının arkasındaki mantığı açıklamaya yönelik mekanizmalar henüz açıklanamamıştır.⁵ Bu nedenle literatürde, derin öğrenmeye dayalı tekniklerin insanların yerini alıp alamayacağını test etmek ve performansın arkasında bulunan nedenleri açığa kavuşturulması gerekliliği araştırmacılar tarafından vurgulanmıştır.²²² Literatürde, adli bilimler kapsamında yaş tahmini alanında derin öğrenme tekniklerinden faydalanılarak çeşitli amaçlarla çalışmalar gerçekleştirilmiştir.

Dişlerin Evrelendirilmesi Amacıyla Gerçekleştirilen Çalışmalar

Literatürde yaş tahmini alanında gerçekleştirilen yapay zeka tekniklerinden derin öğrenme algoritmalarına dayalı çalışmaların bir kısmı diş gelişiminin evrelendirilmesi amacıyla gerçekleştirilmiştir.²¹⁸⁻²²⁰

De Tobel ve arkadaşlarının²¹⁸ 2017 yılında gerçekleştirdikleri pilot çalışmada, mandibular sol yirmi yaş dişinin otomatik olarak evrelendirilmesine yönelik bir sistem önerilmiştir. Çalışmada, metodoloji olarak panoramik radyograflar üzerinde 38 nolu dişlerin etrafına Adobe Photoshop CC 2017 yazılımı kullanılarak manuel olarak standart şekilde dikdörtgen bir sınırlayıcı kutu yerleştirilerek ilgi alanı oluşturulmuştur. Ardından oluşturulan ilgi alanına ait görüntülere MATLAB R2017a yazılımında bulunan çeşitli makine öğrenme algoritmaları uygulanmıştır. Araştırmacılar bir derin öğrenme yaklaşımı olarak Transfer Öğreniminin (AlexNet) evrelendirme için en iyi performansı gösterdiğini bildirmişlerdir. Araştırmacılar çalışmalarında dişlerin evrelendirilmesi için önerdikleri sistemin insan gözlemcilerle benzer bulgular elde ettiğini bildirmişlerdir.²¹⁸

Boedi ve arkadaşları²¹⁹ 2020 yılında, De Tobel ve arkadaşlarının²¹⁸ pilot çalışmasının devamı niteliğinde bir çalışma gerçekleştirmişlerdir.²¹⁹ Araştırmacılar çalışmalarında, mandibular sol yirmi yaş dişinin otomatik olarak evrelendirilmesine yönelik bir sistem önermişlerdir. Araştırmacılar, De Tobel ve arkadaşlarının²¹⁸ pilot çalışmasında dişlerin etrafına manuel olarak çizilen sınırlayıcı kutuların standart bir dikdörtgen olması nedeniyle görüntü alanına giren çevre yapıların sonuçları etkileyebileceği düşüncesiyle 38 nolu dişlerin otomatik segmentasyonu gerçekleştirilerek bir dizi analiz gerçekleştirmişlerdir. Araştırmacılar, bu çalışma ile 38 nolu dişlerin segmentasyonunun, otomatik bir diş gelişimi evreleme sistemi üzerindeki etkisini belirlemeyi amaçlamışlardır. Çalışmada metodoloji olarak, 38 nolu dişlere ait ilgi alanları üç farklı şekilde tasarlanmıştır. Birinci ilgi alanı sınırlayıcı kutu, ikinci kaba segmentasyon ve tam segmentasyondur. Otomatik evrelendirme için ise derin öğrenme metotlarından bir konvolüsyonel sinir ağı olan DenseNet201 algoritması kullanılmıştır. Araştırmanın bulgularına göre DenseNet201 algoritmasının, doğru tahsis edilen aşamaların yüzdesini %3 artırarak De Tobel ve arkadaşları²¹⁸ tarafından kullanılan AlexNet algoritmasına göre daha iyi sonuçlar verdiği bildirilmiştir. Araştırmacılar sonuç olarak, tam segmentasyonun ve DenseNet

algoritmasının birlikte kullanılmasının, dişlerin otomatik olarak evrelendirilmesindeki tahmin performansında artış sağlayacağını bildirmişlerdir.²¹⁹

Banar ve arkadaşları²²⁰ 2020 yılında, diş gelişim evrelerinin tahmininde, prosedürün her adımında konvolüsyonel sinir ağlarının kullanılmasıyla tamamen otomatikleştirmek amaçlı bir pilot çalışma gerçekleştirmişlerdir. Çalışmada önerilen sistemi eğitmek için 7 ile 24 yaş arası bireylere ait, cinsiyet ve gelişim aşaması başına 20 panoramik radyograf içeren 400 görüntüden oluşan bir veri seti kullanılmıştır. Gelişim aşamaları De Tobel ve arkadaşları²¹⁸ tarafından geliştirilmiş Demirjian metodundaki aşamaların genişletilmiş bir versiyonu olan on aşamalı sisteme göre değerlendirilmiştir.²¹⁸ Çalışmada sınırlı bir veri kümesiyle çalışıldığı için transfer öğrenme metotları, önceden eğitilmiş konvolüsyonel sinir ağları ve veri artırma kullanılmıştır. Çalışmada metodoloji olarak üç aşamalı bir prosedür önerilmiş ve sonuçlar beş katlı çapraz doğrulama kullanılarak değerlendirilmiştir. İlk olarak, YOLO benzeri bir eğitilmiş konvolüsyonel sinir ağı ile çevresinde kare şeklinde bir ilgi alanı oluşturulan mandibular sol üçüncü molar dişin geometrik merkezi lokalize edilmiştir. İkinci olarak, U-Net benzeri başka bir konvolüsyonel sinir ağı ile 38 nolu diş, ilgi alanı içinde bölümlere ayrılmıştır. 38 nolu diş gelişim aşamasına göre sınıflandırmak için hem ilgi alanı hem de segmentasyonu kullanan üçüncü ve son bir konvolüsyonel sinir ağı (DenseNet201) sisteme dahil edilmiştir. Bu konvolüsyonel sinir ağı De Tobel ve arkadaşlarının²¹⁸ çalışmasındaki konvolüsyonel sinir ağı ile aynıdır. Araştırmacılar çalışmalarının bulgularına göre otomatik segmentasyon ve evrelendirmenin performansının manuel metotlara göre düşük olduğunu bildirmişlerdir. Ancak araştırmacılar, manuel metotlara göre süreç açısından oldukça hızlı olduğu belirtilen bu çalışmanın umut verici sonuçları olduğunu öne sürmüşlerdir.²²⁰

Yaş Gruplarının Sınıflandırılması Amacıyla Gerçekleştirilen Çalışmalar

Literatürde derin öğrenme teknikleri ile yaş tahmini amacıyla yapılan çalışmaların bir kısmında, yaş tahmini bir sınıflandırma görevi olarak ele alınmıştır.^{221,222} Bu doğrultuda Kim ve arkadaşları²²¹ 2021 yılında, bireylerin yaş grubu sınıflandırmasını yapabilmek amacıyla gerçekleştirdikleri çalışmalarında derin öğrenme tekniklerinden konvolüsyonel sinir ağlarına dayanan bir sistem önermişlerdir. Araştırmacılar bu çalışmada panoramik radyograflar üzerinden birinci molar dişlerin görüntülerinin manuel olarak kırılmasıyla elde edilen görüntüleri

konvolüsyonel sinir ağlarına dayalı bir metodoloji ile değerlendirmişlerdir. Çalışmaya katılan bireyler çocuklar ve ergenler (0-19 yaş), genç yetişkinler (20-49 yaş) ve yaşlı yetişkinler (yaş > 50) olmak üzere üç ana gruba ayrılmışlardır. Araştırmacılar ayrıca en fazla veriye sahip olan genç yetişkin grubunu 20-29 yaş, 30-39 yaş ve 40-49 yaş olmak üzere ayrıca üç alt gruba ayırmışlardır. Çalışmada, yaş grubu tahmini yapılabilmesi için metodoloji olarak derin konvolüsyonel sinir ağı olan ResNet-152 algoritması yaş grubunu dış bazında, yani her diş için ayrı ayrı tahmin edecek şekilde eğitilmiştir. Ancak adli bilimler bağlamında dış bazında tahminin değil, bireyin yaş tahmininin gerçekleştirilmesi önemlidir. Bu nedenden dolayı konvolüsyonel sinir ağı modelinden elde edilen dış bazında tahmin sonuçları, çoğunluk oylama yöntemi kullanılarak birleştirilmiştir. Araştırmacılar, çalışmada önerilen sistemin performansını eğri altındaki alan ve sınıflandırma doğruluğunu kullanarak değerlendirmişlerdir. Çalışmanın bulgularında tek tek dişler için genel doğruluk %87,04 ile %88,33 arasında değişmektedir. Araştırmacılar çalışmanın bulgularına göre, herhangi bir birinci azı dişinin görüntüsünün, bir kişinin yaş grubunu belirlemek için yeterli olduğunu öne sürmüşlerdir. Araştırmacılar çalışmada önerilen sistemin üç ana yaş grubu için gerçekleştirilen deneylerinde, 36 ve 46 nolu dişlerden yaş grubu tahmini için diğer dişlere göre daha yararlı bilgiler elde edildiğini bildirmişlerdir. Ancak sistemin alt grupları da içeren beş yaş grubuyla gerçekleştirilen deneylerinde, yaş grubu tahmininde 16 ve 26 nolu dişlerden diğer dişlere göre daha yararlı bilgiler elde edildiğini bildirmişlerdir. Araştırmacılar bu bulgular ile konvolüsyonel sinir ağı algoritmalarının, girdide var olan bilgilerin hedefler doğrultusunda farklı şekillerde kullanılabileceğini öne sürmüşlerdir. Araştırmacılar bu çalışmada önerilen sistemin odaklandığı bölgeleri görselleştirebilmek adına Grad-CAM ile ısı haritası oluşturmuşlardır. Sistemin odaklandığı bölgeler Tablo 5.5'te gösterilmiştir. Sistemin odaklandığı bölgeler yapılan deneylerin hedeflerine göre bazı değişiklikler göstermiştir. Bu bulgular ile araştırmacılar konvolüsyonel sinir ağları tarafından öğrenilen özniteliklerin ve odaklanılan bölgelerin hedef alınan kriterlere göre değiştiğini öne sürmüşlerdir. Araştırmacılar ayrıca konvolüsyonel sinir ağları ile çoklu görevlerin mümkün olduğunu, ayrıca sistemin birincil hedeflerin yanı sıra hedeflere bitişik alanlardaki yapıları da öğrenerek göreve katkıda bulunduğunu, bunun da hedeflerin doğruluğunu artırdığını bildirmişlerdir.²²¹

Tablo 5.5 Kim ve arkadaşlarının²²¹ çalışmasında kullanılan sistemin odaklandığı bölgeler

Yaş Grupları	3 yaş grubu ile yapılan deneylerde sistemin odaklandığı bölgeler	5 yaş grubu ile yapılan deneylerde sistemin odaklandığı bölgeler
0-9 yaş	İkinci molar dişi ile ilişki ve ikinci molar dişin sürme derecesi	Birinci molar dişin pulpası
10-19 yaş	Alveolar kemik ve maksiller sinüs	Birinci molar dişin pulpası
20-29 yaş	Birinci molar dişin pulpası	Birinci molar dişin periapikal alanı
20-39 yaş	Birinci molar dişin pulpası	Birinci ve ikinci molar diş arasındaki interdental boşluk
40-49 yaş	Birinci molar dişin pulpası	Birinci ve ikinci molar diş arasındaki interdental boşluk ve alveolar kemik seviyesi
50-59 yaş	Birinci ve ikinci molar diş arasındaki interdental boşluk ve alveolar kemik seviyesi	Alveolar kemik seviyesi
+60 yaş	Dişlerin oklüzal seviyeleri	Birinci molar dişin pulpası

Literatürde derin öğrenme tekniklerine dayalı yaş tahmini çalışmalarından, yaş grubu sınıflandırmasına dayanan bir diğer çalışma ise Guo ve arkadaşlarının²²² 2021 yılında gerçekleştirdikleri çalışmadır. Araştırmacılar bu çalışmalarında, Çin ceza hukukuna göre bireylerin adli sorumluluk taşıma durumlarındaki 14, 16 ve 18 yaş eşiklerini sınıflandırmak için derin öğrenme tekniklerine dayalı bir sistem önermişler ve bu sistemi manuel yöntemlerle karşılaştırmışlardır. Çalışmaya 10257 adet panoramik radyograf dahil edilmiştir. Bu çalışmada manuel sınıflandırma için tüm radyograflar, adli tıp eğitimi almış iki uzman tarafından değerlendirilmiştir. Her bir yaş eşiği için, Demirjian metoduna dayanan ve ayrıca sol mandibular üçüncü molar dişin de değerlendirilmeye alındığı ölçümler ile doğrusal regresyon modelleri oluşturulmuştur. Derin öğrenmeye dayalı yaş tahmini için ise konvolüsyonel sinir ağlarından SE-ResNet101 algoritması kullanılmıştır.²²²

Çalışmanın bulgularına göre her bir yaş eşiği için derin öğrenmeye dayalı sisteminin manuel metotlara kıyasla daha iyi performans gösterdiği bildirilmiştir. Araştırmacılar çalışmalarında önerdikleri sistemin odaklandığı alanları görselleştirmek için Grad-CAM ile ısı haritası oluşturulmuştur. Araştırmacılar çalışmada önerilen sistemin düşük yoğunluklu olarak olsa da pulpa odasına, periodontal aralığa, interdental boşluklara, süt ve daimi dişler arasında kalan alana odaklandığını bildirmişlerdir. Araştırmacılar, insan gözlemcilerin radyograflar

üzerinde yalnızca dişler gibi ısı haritalarında yüksek yoğunluklu alanlara denk gelen bölgeleri net bir şekilde tanımlayabildiğini ve değerlendirebildiğini bildirmişlerdir. Ancak derin öğrenme tekniklerinin ısı haritalarında düşük yoğunluklu alanların da özelliklerini öğrenebilmesi ve karmaşık ilişkilerini tespit edebilmesinin hedef görevde performans artışına yol açtığını öne sürmüşlerdir.²²²

Sayısal Regresyon Amacıyla Gerçekleştirilen Çalışmalar

Literatürde derin öğrenme algoritmalarına dayalı yaş tahmini çalışmalarından bazılarında yaş tahmini bir regresyon problemi olarak ele alınmıştır.

Čular ve arkadaşları²²³ 2017 yılında, yaşları 10 ile 25 arasında değişen 203 bireye ait panoramik radyograf üzerinden bir çalışma gerçekleştirmişlerdir. Bu çalışmada araştırmacılar, panoramik radyograflar üzerinden mandibular sağ üçüncü molar dişin incelenmesiyle diş yaşı tahmininde bulunmak amacıyla derin öğrenme tekniklerine dayanan yarı otomatik bir sistem önermişlerdir. Araştırmacılar metodoloji olarak, bu çalışma için seçilen sağ mandibular yirmi yaş dişlerini tanımlayan öznelikleri çıkarmak için yüz tanıma, cinsiyet tahmini ve medikal görüntüleri yorumlama ve bu çalışmalarda öznelik çıkarımı amacıyla yoğun olarak kullanılan Aktif Şekil Modeli (AŞM) ve Aktif Görünüş modeli (AGM) adlı iki istatistiksel bilgisayarlı görme modelini kullanmışlardır. Çalışmanın eğitim setinde segmentasyon manuel olarak gerçekleştirilmiştir. Çalışmada, çıkarılan öznelikler Radial Basis Network adı verilen yapay bir sinir ağına girdi olarak sunulmuş ve çıktı olarak yaş tahmini gerçekleştirilmiştir. Çalışmanın yaş tahmini performansının bulguları yıl cinsinden MAE ile değerlendirilmiştir. MAE, AŞM için 2,481 (SD= 2,148) ve AGM için 2,283 (SD = 2,168) olarak bildirilmiştir. Bu çalışmaların bulgularına göre AGM ile öznelik çıkarılmasıyla sistemin daha iyi performans gösterdiği bildirilmiştir. Çalışmada AGM'nin daha üstün performans gösterdiği bildirilse de AGM ve AŞM'nin birlikte uygulandığı durumda sistemin yaş tahmini performansının kötüleştiği bildirilmiştir.²²³

Araştırmacılar, bu çalışmada segmentasyonun iyi olduğu durumlarda yaş tahmini performansında bir artış gerçekleşmesini beklediklerini bildirmişlerdir. Ancak çalışmanın bulgularına göre segmentasyon hatası varlığında bile kronolojik yaşa çok yakın sonuçlar elde edilmiştir. Dolayısıyla segmentasyondaki hatalar önemsiz olmasa

da bu çalışmada önerilen sistemin kusurlu tanımlayıcılarda bile iyi ve tutarlı tahminler üretilmediği bildirilmiştir. Araştırmacılar MAE'nin 3 yıldan az olmasının umut verici bir ön sonuç olduğunu ve ilerleyen çalışmalarda tahmin hatası azaltılabilirse çalışmalarında önerdikleri türde bir sistemin adli bilimler kapsamında gelecekte kullanılabilir bir sistem olabileceğini bildirmişlerdir. Ayrıca araştırmacılar, bu çalışmada önerdikleri sistemde kullanıcı girdisinin minimum olması ve sistemin çalışması için deneyimli bir diş hekimine ihtiyaç duyulmamasının çalışmanın avantajları olarak bildirmişlerdir.²²³

Çalışmamız, Čular ve arkadaşlarının çalışması ile gerek metodoloji gerek yaş grubu açısından doğrudan kıyaslanabilir bir nitelikte değildir. Literatürde daha genç bireylerde büyüme ve gelişime dair daha fazla yaş göstergesi bulunması nedeniyle genç bireylerin dahil edildiği çalışmalarda MAE değeri genel olarak daha az bildirilmektedir.⁵ Çalışmamız incelenen yaş grubu olarak 6 ile 15 yaş aralığındaki bireylere odaklanmaktadır. Dolayısıyla çalışmamızın Čular ve arkadaşlarının çalışmasına kıyasla MAE değerinin düşük olması beklenen bir bulgudur.

Çalışmamızın bu çalışmanın aksine yaş tahmini yapılırken radyograflar üzerinden segmentasyon gibi bir manuel adım içermemesi çalışmamızda kullandığımız sistemin bir avantajı olarak gösterilebilir. Ayrıca çalışmamızda, sol yedi mandibular daimi dişi içeren panoramik radyograf kesitlerinin kullanılması nedeniyle, en sık konjenital eksikliği görülen üçüncü molar dişlere ihtiyaç duyulmaması çalışmamızın başka bir avantajı olarak gösterilebilir.

Tablo 5.6 Çalışmamızın Čular ve arkadaşlarının²²³ çalışmasına ait bulgular ve çalışmamızın bulgularıyla kıyaslaması

	MAE	SD
AŞM	2,481	2,148
AGM	2,283	2,168
Bizim Çalışmamız	0,0079	0,0004

De Back ve arkadaşları²²⁴, 2019 yılında, adli yaş tahminini otomatikleştirme, standartlaştırma ve nesnelleştirme amacıyla, 5-25 yaş arasındaki bireylere ait 12000 panoramik radyograf üzerinden bir çalışma gerçekleştirmişlerdir. Araştırmacılar bu çalışmada, diş yaşı tahmini için derin öğrenme algoritmalarından Bayesian konvolüsyonel sinir ağlarına dayalı bir sistem önermişlerdir. Önerilen sistemin

performansı uyum korelasyon katsayısı adlı metrik ile değerlendirilmiş ve değeri 0,910 olarak belirlenmiştir.

Bu çalışmanın metodolojisinde, diş yaşı tahmini, bir regresyon problemi olarak ele alınmıştır. Problemin çözümü amacıyla, panoramik radyograflardaki özneliklerin çıkarılması için konvolüsyonel sinir ağlarından InceptionV3 mimarisi ve diş yaşı tahmini için ise Bayesian konvolüsyonel sinir ağlarına dayalı bir sistem tasarlanmıştır. Bu çalışmada, önerilen sistemin girdisini oluşturan panoramik radyografların hangi bölgelerinin diş yaşı tahmininde önemli olduğunu keşfetmek için çalışmanın veri setini oluşturan bireyler yaş gruplarına ayrılmış DeepLIFT yazılımı kullanılarak açıklayıcı belirginlik haritaları oluşturulmuştur. Çalışmanın bulgularına göre MAE değeri 1,75 yıl olarak bildirilmiştir. Araştırmacılar yaptıkları çalışmanın bulgularına göre diş yaşı tahmininde en bilgilendirici bölgenin molar dişler bölgesi olduğunu bildirmişlerdir. Ayrıca araştırmacılar genç bireylerde maksiller sinüslerin, yaşlı bireylerde ise nazal septumun yaş tahmini için bilgilendirici bir rol oynadığını öne sürmüşlerdir. Araştırmacılar bu çalışmanın sonuçlarının henüz rutin kullanıma uygun olmadığını bildirseler de yaş tahmini için yeni potansiyel belirteçlere ışık tutabileceği nedeniyle çalışmanın önemli olduğunu bildirmişlerdir.²²⁴

Diş gelişiminin tamamlanmasından sonra panoramik radyograflardaki diş yaşına dair göstergeler giderek azalmaktadır. Bu durum diş gelişimi tamamlanmış yaştaki bireylerin dahil edildiği otomatik yaş tespit çalışmalarının başarısını düşüren bir durum olarak ifade edilmektedir.⁵ Çalışmamız, De Back ve arkadaşlarının çalışmasına göre daha genç bir yaş grubuna odaklanmaktadır. Çalışmamızın MAE değerinin düşük olması bu sebebe bağlı olabileceği düşünülmektedir. Ayrıca çalışmamızda birçok yapay zeka tekniğinin bir arada kullanılması nedeniyle De Back ve arkadaşlarının çalışmasında kullanılan sisteme göre daha iyi bir performans elde edildiği düşünülmektedir.

Wallraff ve arkadaşları²²⁵, 2021 yılında, geleneksel manuel yaş tahmin metodlarındaki bir dezavantaj olan tahmin hatasını azaltmak amacıyla otomatik olarak yaş tahmini gerçekleştirmeye yönelik bir çalışma gerçekleştirmişlerdir. Bu çalışmada araştırmacılar yaş tahmini gerçekleştirmek için denetimli regresyona dayanan bir derin öğrenme sistemi önermişlerdir. Çalışma 11 ile 20 yaş arasındaki bireylere ait 14000 adet panoramik radyograf üzerinden gerçekleştirilmiştir. Çalışmada önerilen sistemde

girdi olarak ham panoramik radyograflar kullanılmaktadır. Görüntülerin önceden işlenmesi ve kırılması gerekmemektedir. Araştırmacılar, yaşamın ilk yirmi yılında dişlerin öngörülebilir bir düzende gelişmesi nedeniyle bu çalışmanın odağının 11-20 yaş olduğunu bildirmişlerdir. Veri setindeki düşük kontrastlı görüntüler, hastalıklar ve çene malpozisyonlar gibi çeşitli dış unsurlardan etkilenen radyograflar çalışma kapsamı dışında tutulmamıştır. Çalışmada 244 görüntü test grubu olarak ayrılmıştır. Deneyimli bir Ağız Diş ve Çene Cerrahi uzmanı ve yaş tahmini eğitimi almış üç diş hekimliği öğrencisi tarafından test grubundaki görüntülerde manuel olarak yaş tahmini yapılmıştır. Bu çalışmada yaş tahmini bir regresyon problemi olarak ele alınmıştır ve önerilen sistemde ağ mimarisi olarak ResNet18 algoritması kullanılmıştır. Çalışmada önerilen sistemin MAE'si 1,08 yıl SD'si +1,41 ve hata oranı %17,52 olarak bildirilmiştir. Cinsiyet, diş gelişimi üzerinde etkili bir faktör olduğu için cinsiyete özgü olan ve olmayan iki algoritma karşılaştırılmıştır. Çalışmanın bulgularına göre cinsiyete özgü mimarinin çalışma popülasyonundaki kadın bireyler için doğruluğu yükselttiği ve hata oranını düşürdüğü ancak, MAE değerinde bir artış meydana getirdiği bildirilmiştir. Ancak önerilen sistemin cinsiyete yönelik eğitiminin erkek bireylerde performansta herhangi bir iyileşmeye sebep olmadığı bildirilmiştir.²²⁵

Bu çalışmada önerilen sistemin ele aldığı görüntülerin özelliklerinin daha iyi anlaşılabilmesi için, cinsiyete özgü olmayan mimari Grad-CAM ile analiz edilmiştir. Oluşturulan ısı haritaları ile yapılan analizlerde çalışmada önerilen sistemin esas odak noktasının dişlerin bulunduğu bölge olduğu bildirilmiştir. Araştırmacılar yanlış tahminlerde bulunulan görüntüleri incelediklerinde, yanlış tahminde bulunulan bireylerin görüntülerinde, genel olarak görüntü kalitesinde yetersizlik ya da panoramik radyograflarda radyolojik bulgu veren bir sistemik hastalığa sahip olma gibi çalışma popülasyonu ile ortak paydada olmayan özelliklerin olduğunu bildirmişlerdir. Araştırmacılar bu çalışmada sonuç olarak cinsiyete özgü mimarinin yaş tahmin performansında artışa sebep olabileceğini bildirmişlerdir. Ayrıca araştırmacılar çalışmalarındaki veri seti ile 11-20 yaş aralığı için kapsamlı veriler sağladıklarını ve ilerleyen dönemde önerilen sisteme 0-20 yaş aralığındaki bireylerin dahil edilmesi gerektiğini ifade etmişlerdir.²²⁵

Literatürde yaş ile ilgili göstergelerin büyüme ve gelişim ilerledikçe azalması nedeniyle incelenen yaş gruplarının daha genç olduğu çalışmaların hata oranlarının

daha düşük olarak tespit edildiği bildirilmektedir.⁵ Wallraff ve arkadaşlarının çalışmasında 11 yaşından küçük bireyler çalışmalarının kapsamı dışında tutulmaktadır. Çalışmamız, Wallraff ve arkadaşlarının çalışması ile karşılaştırıldığında, çalışmamızın MAE değerinin belirgin olarak düşük olduğu gözlenmiştir. Bu bulgunun sebebinin, çalışmamızın yaşça daha genç bireylere odaklanmasından kaynaklandığı düşünülmektedir.

Vila-Blanco ve arkadaşları⁶, 2020 yılında yaptıkları çalışmalarında, geleneksel metotlarda yaş tahmini işlemleri yapılırken gözlemci öznelliğinden etkilenmesi ve zaman alıcı manuel işlemlere bağlı olması gibi dezavantajlarının üstesinden gelmek amacıyla panoramik radyograflar üzerinden tam otomatik olarak yaş tahmin etmek amacıyla derin öğrenme algoritmalarına dayanan bir yöntem önermişlerdir. Çalışma, İspanyol popülasyonuna ait, yaşları 4,5 ile 89 arasında değişen 2289 bireye panoramik radyograflar üzerinden gerçekleştirilmiştir. Çalışmaya dahil etme kriteri olarak yalnızca panoramik radyografların iyi kalitede olması gözetilmiştir. Literatürdeki klasik metotlardan farklı olarak ortodontik braketi veya apareyi bulunan, protez, implant, restoratif materyal, dolgu, endodontik tedavi, çürük, eksik diş, rezidüel diş kökü veya küpe gibi yabancı cisim içeren, bozuk veya bulanık görüntü gibi dış unsurlara sahip panoramik radyograflar çalışmanın kapsamı dışında tutulmamıştır. Bu görüntüler sistemde kusurlu olarak etiketlenmiştir. Bu çalışmada metodoloji olarak tıbbi görüntüler üzerindeki performansları yüksek düzeyde olması nedeniyle derin öğrenme algoritmalarından konvolüsyonel sinir ağları kullanılmıştır. Bu çalışmada DANet ve DASNet olarak iki farklı ağ mimarisi geliştirilmiştir. Bu mimariler bu çalışma için yaş tahmini gerçekleştirmek amacıyla özel olarak tasarlanıp eğitilmişlerdir.⁶

DANet, yaş tahmini amacıyla görüntü özniteliklerini öğrenmek ve yaş tahmin etmek için konvolüsyon ve havuzlama katmanlarının bulunduğu tek bir konvolüsyonel sinir ağı yoludur. DASNet'te ise cinsiyet tahmini için sisteme ilkiyle tamamen benzer ikinci bir konvolüsyonel sinir ağı yolu eklenir. Ancak DASNet'te amaç cinsiyet tahmini yapmak değildir. Cinsiyet yolu, cinsiyete özgü öznitelikleri kullanması için, öğrendiği bilgileri yaş yolu ile paylaşmaktadır. Bu şekilde, yaş tahmin sürecini iyileştirmek için cinsiyet bilgisi dikkate alınmaktadır. Çalışmada son olarak önerilen kronolojik yaşı tahmin etmek için odaklandığı görüntünün bölgelerini belirlemek için

ağın davranışı analiz edilmiştir. Görüntü dikkat haritalarını oluşturmak için Grad-CAM yöntemi kullanılmıştır. Çalışmanın bulgularına göre hem DANet hem de DASNet sisteminin yaş ile yüksek korelasyon gösterdiği bildirilmiştir. DANet için determinasyon katsayısı $R^2=0,87$ ve DASNet için ise $R^2=0,90$ olarak bulunmuştur. Tüm yaş gruplarına ait verilerin değerlendirilmesinde MAE 2,84 yıl olarak bildirilmiştir. Bireylerin yaşları küçüldükçe, MAE değeri, 15 yaşından küçük bireylerin bulunduğu grupta DANet için 0,78 yıl, DASNet için ise 0,75 yıl olarak tespit edilmiştir. Yapılan Grad-CAM ısı haritası değerlendirmesine göre ise sistemin odaklandığı bölgeler değişiklik göstermiştir. Ancak genel olarak mandibular molar dişlerin yaş tahminine daha fazla katkıda bulunduğu bildirilmiştir. Bu davranış modeli özellikle 25 yaşından küçük bireylerde belirgin olarak izlenmiştir. Çalışmanın bulgularına göre tüm yaş gruplarında DASNet DANet'e göre daha iyi performans gösterdiği bildirilmiştir. Araştırmacılar tüm veri seti ile yapılan deneylerin sonuçlarının 15 yaşından küçük bireylerle yapılan deneylerin sonuçlarından daha kötü performans gösterdiğini ve sisteme yaşlı bireylerin eklenmesiyle tahmin performansının kötüleştiği bildirilmiştir. Araştırmacılar, bu bulgunun daimi dişlerin gelişiminin tamamlandığı 25 yaşından daha büyük bireylerde gelişimsel yaş göstergelerinin azalması nedeniyle yaş tahmini yapmanın zorluğunu doğrular nitelikte olduğunu öne sürmüşlerdir. Ayrıca önerilen yaklaşımın hedef alınan popülasyona bağlı olarak uyarlanması gerektiğini bildirmişlerdir. Sonuç olarak araştırmacılar, bu çalışmada önerilen DASNet yönteminin, özellikle gelişmekte olan dişlere sahip genç bireylerde, kronolojik yaşı otomatik ve doğru bir şekilde tahmin etmek için kullanılabilir bir yöntem olduğunu bildirmişlerdir.⁶

Çalışmamızda, Vila-Blanco ve arkadaşlarının çalışmasından farklı olarak sisteme giriş verisi olarak sol yedi mandibular daimi dişi içeren panoramik radyograf kesiti sunulmuştur. Vila-Blanco ve arkadaşlarının çalışmasında ise ham panoramik radyograflar sisteme giriş verisi olarak sunulmuştur ve herhangi bir dışlama kriteri bulunmamaktadır. Ancak çekim kalitesi yetersiz radyograflar sisteme kusurlu olarak etiketlenip sunulmuştur. Çalışmamız, herhangi bir dişsel veya kemiksel patolojiye sahip olmayan bireylere ait yüksek kalitedeki radyograflar ile gerçekleştirilmiştir. Bu durumun, çalışmamızda kullanılan sistemin başarısının artmasına katkıda bulunduğu düşünülmektedir.

Çalışmamız, odaklanılan yaş grubu yönünden incelendiğinde, Vila-Blanco ve arkadaşlarının çalışmasından çok daha genç bir popülasyonu incelemektedir. Gelişimsel yaş göstergelerin küçük yaşlarda daha yoğun bir biçimde bulunduğu göz önüne alındığında çalışmamızın bulgularının performansının Vila-Blanco ve arkadaşlarının çalışmasından daha iyi performans göstermesinin arkasında yatan sebep olabileceği düşünülmektedir.

Ayrıca metodoloji olarak derin öğrenme tekniklerinin makine öğrenmesi teknikleriyle bir arada kullanılmasının çalışmamızdaki sistemin başarımını artıran bir unsur olduğu düşünülmektedir.

Vila-Blanco ve arkadaşları¹⁹⁸, 2022 yılında yaş ve cinsiyet tahmini yapmak amacıyla gerçekleştirdikleri çalışmalarında panoramik radyograflar üzerinden tam otomatik bir sistem önermişlerdir. Araştırmacılar bu çalışmayı, literatürdeki derin öğrenme ile gerçekleştirilmiş otomatik yaş tahmini çalışmaların metodolojilerindeki farklılıklar nedeniyle, ısı haritalarıyla görselleştirme yapılsa bile yorumlanabilirlik açısından manuel metotların oldukça gerisinde kalması dezavantajının üstesinden gelmek amacıyla gerçekleştirmişlerdir. Çalışma, İspanyol popülasyonundan yaşları 5 ile 60 arasındaki 872 kadın ve 874 erkek bireye ait panoramik radyograf üzerinden gerçekleştirilmiştir. Çalışmanın metodolojisinde herhangi bir dışlama kriteri bulunmamaktadır. Bir uzman tarafından panoramik radyograflar üzerinden, her bir diş için bir bilgisayar yazılımı aracılığıyla sınırlandırıcı kutu çizimi gerçekleştirilmiştir. Çalışmada yaş ve cinsiyet tahmini mandibular kanin, premolar ve molar dişler kullanılarak gerçekleştirilmiştir. Çalışmada bu dişlerin seçilmesinin nedeni, panoramik radyografların geometrisi nedeniyle maksiller dişlerin özellikle premolar bölgede mandibular eşleniklerine göre daha fazla süperpozisyon göstermesi ve hem maksilla hem mandibula anterior bölgede servikal vertebraların hayalet görüntülerinin dişlerin üzerine süperpozisyonudur.¹⁹⁸

Bu çalışmanın metodolojisi iki adımdan oluşmaktadır. Çalışmanın ilk kısmında görüntüde seçilen dişin hangi diş olduğunu otomatik tahmin etmek için bir konvolüsyonel sinir ağı kullanılmıştır. Bu ağ kullanılarak otomatik olarak her bir dişin olduğu bölgede dişlerin morfolojisine göre açılanmış sınırlayıcı kutular oluşturulmuştur. Sınırlayıcı kutuların açılı olması sayesinde görüntüye komşu dişlerin girmesi engellenmiştir. Çalışmanın ikinci kısmında ise, ilk konvolüsyonel sinir ağı

tarafından dişlerin konumlarından alınan görüntü bilgisi, diş başına kronolojik yaş ve cinsiyet olasılık dağılımlarını tahmin etmek için bir dizi konvolüsyonel katman ve tamamen bağlantılı bir katman uygulayan ikinci bir konvolüsyonel sinir ağına beslenmiştir. Sistem her diş için tek bir nokta tahmini vermek yerine, yaş tahmini için Gauss ve cinsiyet sınıflandırması için Bernoulli olasılık dağılımı vermektedir. Bu diş başına dağılımlar nihai tahmin için belirsizlikler dikkate alınarak, yani her bir dağılımın ortalamasına dağılımın varyansı ile ters orantılı bir ağırlık veren ağırlıklı bir toplam aracılığıyla toplanmaktadır. Çalışmanın bulgularına göre yaş tahmini için MAE değeri 0,97 ve R^2 değeri 0,94 olarak bildirilmiştir. Araştırmacılar çalışmada önerilen sistem ile tek bir dişin varlığında dahi yaş ve cinsiyet tahmini gerçekleştirilebileceğini ancak daha fazla dişin bulunduğu durumlarda önerilen sistemin performansının artacağını bildirmiştir.¹⁹⁸

Vila-Blanco ve arkadaşlarının çalışması ile kıyaslandığında çalışmamızın daha genç bir popülasyona (5-15 yaş) odaklandığı görülmektedir. Diş gelişiminin sona ermesi, 20 yaşından büyük bireylerin dahil edildiği çalışmaların performansının azalmasının sebebi olarak gösterilmektedir. Bu durumun, çalışmamızın MAE ve R^2 bulguların yönünden daha üstün bir performans göstermesinin sebebini açıklıyor olabilir.

Ayrıca Vila-Blanco ve arkadaşlarının çalışmasında ham panoramik radyograflar sisteme giriş verisi olarak sunulmaktadır ve herhangi bir dışlama kriteri bulunmamaktadır. Çalışmamızda ise sol yedi mandibular daimi dişi içeren panoramik radyograf kesiti sisteme giriş verisi olarak sunulmuştur. Herhangi bir dişsel veya kemiksel patolojinin olduğu radyograflar veya çekim kalitesi düşük olan radyograflar çalışmamızın kapsamı dışında tutulmuştur. Bu durumun, çalışmamızda kullanılan sistemin başarımının artışına sebep olduğu öne sürülebilir.

Milošević ve arkadaşları⁵ 2020 yılında, yetişkin ve ileri yaştaki bireylerde derin öğrenme algoritmalarının panoramik radyograflar üzerinden kronolojik yaş tespiti için uygulanabilirliğini araştırdıkları bir çalışma yapmışlardır. Araştırmacılar bu çalışmada derin öğrenme algoritmalarından konvolüsyonel sinir ağlarını kullanarak en iyi performansı gösteren modeli bulmak için çeşitli deneyler gerçekleştirmişlerdir.

Çalışmada önerilen model, girdi olarak bir panoramik radyografi almakta ve çıktı olarak, yıl cinsinden yaş tahminini temsil eden bir sayı vermektedir. Ayrıca araştırmacılar, panoramik radyograflardaki hangi bölgenin diş yaşı tahminine en çok katkıda bulunduğunu tespit etmek için panoramik radyografların çeşitli bölgelerinin çıkarıldığı ablasyon deneyleri gerçekleştirmişlerdir.⁵

Çalışmanın veri setini 19 ile 90 yaş arasındaki yetişkin bireylere ait 4035 adet panoramik radyograf ve bu radyograflarda bulunan 76416 diş oluşturmaktadır. Çalışmanın gerçekleştirildiği bireylerde bulunan diş çürükleri, patolojik durumlar gibi panoramik radyograf görüntülerini etkileyen diş unsurların, çalışmada önerilen model için sorun teşkil etmediği bildirilmiştir. Bu çalışmada, konvolüsyonel sinir ağı mimarileri öznitelik çıkarılması amacıyla kapsamlı bir şekilde değerlendirilmiş ve panoramik radyograflar üzerinden çıkarılan öznitelikler, yaş tahmini modeli oluşturabilmek amacıyla için bir başlangıç noktası olarak kullanılmıştır.⁵

Araştırmacılar, arkeolojik bağlam göz önüne alındığında ya da adli olgularda delil olarak tüm çeneyi ve tüm dişleri içeren delillerden ziyade bir veya birkaç diş bulmanın daha olası olduğunu bildirmişlerdir. Dolayısıyla çalışmalarını, bu problem göz önünde bulundurularak planlamışlardır. Araştırmacılar çalışmada önerilen yaş tahmin modelinin panoramik radyograflar üzerindeki tek tek diş görüntüleri üzerinde de uygulanabilirliğini ve performansını değerlendirmişlerdir. Önerilen sistemin hızlı, tekrarlanabilir ve performans açısından klasik yaş tahmin metotlarıyla rekabet edebilecek nitelikte olduğunu öne sürmüşlerdir.⁵

Çalışmanın ilk kısmında öznitelik çıkarımı için; DenseNet201, InceptionResNetV2, Ioffe, ResNet50, VGG16, VGG19 ve Xception adlı önceden eğitilmiş konvolüsyonel sinir ağı mimarileri ile transfer öğrenme yaklaşımı test edilmiştir. En yüksek performansın VGG16 algoritması ile elde edildiği bildirilmiştir. Çalışmada yaş tahmini problemine görüntü analiz problemi olarak yaklaşmış, tahmin görevi ise bir regresyon problemi olarak formüle edilmiştir.⁵

Çalışmada, anatomik olarak hangi bölgelerin yararlı yaş göstergeleri içerdiğini belirlemek için yapılan ablasyon deneylerinde üç ayrı model belirlenip sistemin eğitimi sağlanmıştır. Birinci model, çevre kemik yapının görüntüden çıkarıldığı, yalnızca diş içeren görüntüler üzerinde eğitilmiştir. İkinci model, dişlerin etrafındaki

kemik yapının korunarak bloke edildiği görüntüler üzerinde eğitilmiştir. Üçüncü model ise her bir dişin ayrı ayrı bloke edildiği görüntüler üzerinde eğitilmiştir. Bu çalışmada önerilen sistemin performansı üç farklı metrikle ölçülmüştür. Bunlar yıl cinsinden MAE, medyan AE ve R^2 değeridir.⁵

Tablo 5.7 Milošević ve arkadaşlarının⁵ çalışmasına ait bulgular

	MAE	medyan AE	R^2
Yalnızca dişlerin görüldüğü merkez bölgeden yaşı tahmin eden model	4,65 yıl	3,62 yıl	0,7820
Dişlerin görünmediği bölgelerinden yaşı tahmin eden model	5,06 yıl	4,12 yıl	0,7481
Tek tek dişler üzerinden eğitilen model	6,30- 8,68 yıl aralığında (Dişe bağlı olarak)	4,68-7,33 yıl aralığında (Dişe bağlı olarak)	-
Ham görüntü üzerinden yaşı tahmin eden model	3,96 yıl	2,97 yıl	0,8439

Araştırmacılar bu çalışmanın bulgularında, yaş grupları dikkate alındığında ilerleyen yaşla birlikte belirgin bir performans düşüşü gözlemlendiğini bildirmişlerdir. Araştırmacılar bunun iki sebebi olduğunu öne sürmüştür. İlk faktör, veri setini oluşturan katılımcıların çoğunun genç ve kadın katılımcılara ait olmasıdır. Bu gruptaki verilerin fazla olması nedeniyle, çalışmada önerilen sistemin bu bireylere ait verilerde ayırt edici özellikleri bulmaya önyargılı olacağı bildirilmiştir. Diğer faktörün de yaş ile birlikte, çürükler, aşınma ve çevre kemik dokudaki değişimler gibi dış kaynaklı hasarların birikmesi yaş göstergelerini zayıflatması olduğu öne sürülmüştür. Araştırmacılar, çocuklarda aşınma ve patolojik durumların azlığı gelişimsel göstergelerin varlığıyla birleştiğinde yaş tahmininin daha başarılı olduğunu bildirmişlerdir. Bu sebeple odaklanılan grubun çocuklar olduğu çalışmaların başarımının artacağını ve MAE değerinin azalacağını bildirmişlerdir.⁵

Araştırmacılar bu çalışmada yaş tahminine yalnızca dişlerin mi katkıda bulunduğunu araştırmak için gerçekleştirdikleri çeşitli deneylerin bulgularına göre yaş tahmini yapılırken en bilgilendirici yapıların dişler olduğunu bildirilmişlerdir. Dişlerin kapatıldığı, sadece çevre kemik yapının incelendiği görüntüler üzerinden yapılan deneylerde performans azalsa da yine de yaş tahmininde faydalı göstergeler bulunduğu bildirilmiştir. Ancak araştırmacılar yine de dişlerin ve çevre kemik yapıların birlikte

bulduğu görüntülerin ayrı ayrı yapılan değerlendirmelerden daha üstün bir performans sergilediği bildirmişlerdir.⁵

Araştırmacılar bu çalışmanın sonucunda, yetişkin bireylerde yaş tahmini yapılırken derin öğrenme algoritmalarının yalnızca uygulanabilir olduğunu değil, klasik metotlardan daha iyi performans gösterdiğini de bildirmişlerdir. Araştırmacılar, 65 yaşından büyük bireylerin bulunduğu gruptaki bulguların rutin uygulamalarda kullanılabilirlik açısından yetersiz olduğunu ancak yetişkinlerdeki otomatik yaş tahmini alanında bir gelişme olduğunu bildirmişlerdir. Ayrıca bu çalışmanın bulguları ile, ileri yaş gruplarında yapılan değerlendirmelerde yaş tahmini için gelişimsel olmayan birtakım göstergelerin de varlığına dikkat çekilmiştir.⁵

Milošević ve arkadaşlarının çalışması, gerek metodoloji gerekse odaklanılan yaş grubu bakımından çalışmamızla doğrudan kıyaslanabilir olmasa da, literatürde derin öğrenme algoritmalarının yetişkin ve ileri yaştaki bireylerde yaş tahmini için uygulanabilirliğini göstermesi ve derin öğrenme algoritmalarının manuel hesaplama için mümkün olmayan bir dizi özelliği ve özelliklerin ilişkisini keşfetme konusunda belirgin yeteneğe sahip olması noktasında önemli bir çalışma olarak karşımıza çıktığı söylenebilir.

5.2.3 Derin Öğrenme ve Makine Öğrenimine Dayalı Hibrit Çalışmalar

Yaş tahmini, tahmin yapılırken işlem süresinin hayati olduğu, zamana duyarlı bir konudur. Veri işleme için veri madenciliği tabanlı yöntemlerde son zamanlarda kaydedilen ilerleme ile, görüntü işleme süresi ve tahmin işlemi için gereken süre önemli ölçüde azaltmıştır. Literatürde otomatik görüntü işleme teknikleri ile yaş tahmini hassasiyetinin ± 1 yıl aralığına yükseldiği bildirilmiştir. Bu tahmin hassasiyeti genellikle doğru bir ölçüm olarak kabul edilse de cinayetler, toplu afetler gibi adli olgularda tahmin edilen yaşın mümkün olduğunca kronolojik yaşa yakın olması gereklidir. Araştırmacılar, bu sebeple makine öğrenimi tabanlı tekniklerin başka tekniklerle birleştirilerek yapay zeka kullanılarak gerçekleştirilen yaş tahmininin daha da geliştirilmesi gerektiğini öne sürmüşlerdir.²²⁶

Sharifonnasabi ve arkadaşları²²⁶ tarafından, 2022 yılında sayısal yaş regresyonu yapmak için Malezya popülasyonuna ait yaşları 15 ila 23 arasında değişen 1922 bireye ait panoramik radyograf yapay zeka algoritmalarından konvolüsyonel

sinir ađlarına ve makine öğrenimi algoritmalarından KNN tekniđine dayanan bir hibrit model geliřtirilmiřtir. Bu çalıřmanın metodolojisinde overfittingi (ařırı uydurma) önlemek için temel bileřen analizi algoritması kullanılarak yüksek korelasyon gösteren öznitelikler ortadan kaldırılmıřtır. Çalıřmada önerilen hibrit modelin performansını artırmak için, veri seti görüntü ön iřleme sürecinden geçirilmiřtir. Çalıřmanın veri setini oluřturan bireylerin yařları yıllık (15 yař, 16 yař,), 6 aylık (15 yař, 15,5 yař...), üç aylık (15yař 0-3 ay, 15 yař 3-6 ay, 15 yař 6-9 ay, 15 yař 9-12 ay) ve aylık (15 yař 1 ay, 15 yař 2 ay.. gibi) gösterim biçimleriyle dört farklı řekilde temsil edilmiřtir. Sonuç olarak çalıřmada önerilen hibrit modelin veri setine ait gruplar için yař tahminini, sırasıyla %99,98, %99,96, %99,87 ve %98,78 dođrulukla yaptıđı bildirilmiřtir.²²⁶

Çalıřmamız, Sharifonnasabi ve arkadaşlarının çalıřması ile metodoloji olarak dođrudan kıyaslanamamaktadır. Ancak bu çalıřma, bulguları yönünden incelendiđinde, çalıřmamızla benzer biçimde, birçok tekniđin bir arada kullanılmasının, yař tahmini için kullanılan yapay zeka sistemlerindeki performansa olumlu katkıları olduđunun bildirilmesi ađısından dikkat çekicidir.

6. SONUÇ ve ÖNERİLER

Yapay zeka algoritmalarından faydalanılarak oluşturulmuş sistemler ile problemlerin çözümünde işlem süresi önemli ölçüde kısaltılmaktadır. Ayrıca bu sistemler ile tutarlı ve tekrarlanabilir yüksek performanslı sonuçlar ortaya konmaktadır.

Derin öğrenme algoritmaları ile önerilen sistemler, insan gözü ile tespit edilemeyecek bazı özellikleri ve bu özelliklerin arasındaki ilişkiyi tespit edebilmesi nedeniyle çok yüksek performans sunmaktadır. Ancak yine aynı nedenle, bu sistemlerin performansının altında yatan mekanizmalar henüz tamamen açıklanabilmiş değildir. Bu durum, bu sistemlerin yorumlanabilirliği açısından bir dezavantaj taşımaktadır.

Bu dezavantajın üstesinden gelmek ve yorumlanabilirliği geliştirmek için bazı araştırmacılar ısı haritaları gibi bazı görselleştirme tekniklerine başvurursa da temelde çalışma bulgularının arkasındaki mantığı açıklamaya yönelik mekanizmalar henüz açıklanamamıştır. Bu nedenle gelecekte, derin öğrenmeye dayalı tekniklerin insanların yerini alıp alamayacağını test etmek ve performansın arkasında bulunan nedenleri açığa kavuşturulması amacıyla çalışmalar gerçekleştirilmelidir.

Çalışmamızda, panoramik radyograflar ve hasta kayıtlarını kapsayan bir veri setinden yaş tahmini amaçlanmıştır. Çalışmamızda, öznelik çıkarımı için 1D-DCNN ve 2D-DCNN ve yaş tahmini için regresyon adımında GA ve RF algoritması modifiye edilerek birleştirilmiş ve MG-RF olarak adlandırılmıştır.

Çalışmamızda kullanılan sistem, gerçek yaş değeri ile tahmin edilen yaş değeri arasındaki değişimler analiz edilerek değerlendirilmiştir. Çalışmamızın sonucunda, bu iki değer arasında yüksek korelasyon olduğu görülmüştür.

Literatürde yapay zeka algoritmaları ile gerçekleştirilmiş çok az çalışma olması ve bu çalışmaların metodoloji olarak birbirinden çok farklı algoritmalara dayanmasından dolayı çalışmalar arasında doğrudan karşılaştırma yapabilmek mümkün olmamaktadır. Ancak bu çalışmaların etkinliği, bulguların değerlendirildiği ortak performans metrikleri açısından kıyaslanabilmektedir. Çalışmamızda kullanılan sistemin performansı, kodun uygulanması sırasında ölçülen MAE, MSE, RMSE, SD

ve R^2 metrikleri açısından yapay zeka algoritmalarının kullanıldığı çalışmalar ile karşılaştırmalı olarak incelenmiştir.

Çalışmamızın bulgularına göre, çalışmamızda kullanılan sistemin SD değerinin 0,0004, MAE değerinin 0,0079, MSE değerinin 0,00027, RMSE değerinin 0,0888 ve R^2 değerinin 0,9999 olduğu belirlenmiştir. Yapılan karşılaştırmalar sonucunda, çalışmamızda kullanılan sistemin, karşılaştırılma yapılan performans metrikleri yönünden, metodoloji olarak yapay zeka algoritmalarının kullanıldığı diğer çalışmalardan daha iyi performans gösterdiği sonucuna varılabilir.

Gelecekte yapılacak çalışmalarda, ısı haritası ile görselleştirme gibi özellikler ek olarak dahil edilebilir ve yaş tahmin oranı belirlenebilir. Ayrıca çalışmamızda kullandığımız sistemin daha ileri yaşlardaki bireyler üzerindeki etkinliğini ölçen çalışmalar gerçekleştirilebilir.

Sonuç olarak adli bilimlerde, doğumdan ergenlik çağına kadar, tahmin edilen diş yaşı ve kronolojik yaş arasındaki kabul edilebilir farkının ± 1.00 yıl olarak bildirilmesi nedeniyle çalışmamızın yaş tespitinde önemli ölçüde etkili bir performans gösterdiği sonucuna varılabilir. Bu nedenle çalışmamızda kullanılan sistemin gelecekte adli bilimler kapsamında kullanılabilir bir nitelik taşıyabileceğini düşünmekteyiz.

KAYNAKLAR

1. Harorlı A. Adli diş hekimliği. Atatürk Üniversitesi Yayınları, Ders Kitapları Serisi 1. 2006.
2. Willems G. A review of the most commonly used dental age estimation techniques. *J Forensic Odontostomatol.* 2001;19(1):9–17.
3. Ge Z pu, Ma R han, Li G, Zhang J zong, Ma X chen. Age estimation based on pulp chamber volume of first molars from cone-beam computed tomography images. *Forensic Sci Int.* 2015; 253:133.e1-133.e7.
4. Sakuma A, Saitoh H, Suzuki Y, Makino Y, Inokuchi G, Hayakawa M, et al. Age Estimation Based on Pulp Cavity to Tooth Volume Ratio Using Postmortem Computed Tomography Images. *J Forensic Sci.* 2013;58(6):1531–5.
5. Milošević D, Vodanović M, Galić I, Subašić M. Automated estimation of chronological age from panoramic dental X-ray images using deep learning. *Expert Syst Appl.* 2022;189.
6. Vila-Blanco N, Carreira MJ, Varas-Quintana P, Balsa-Castro C, Tomas I. Deep Neural Networks for Chronological Age Estimation From OPG Images. *IEEE Trans Med Imaging.* 2020;39(7):2374–84.
7. Uzun T. Yapay zeka ve sağlık uygulamaları. İzmir Kâtip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi. 2020;3(1):80–92.
8. Pirim H. Yapay zeka. Yaşar Üniversitesi E-Dergisi. 2006;1(1):81–93.
9. Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofacial Radiology* [Internet]. 2022;51(1). Available from: <https://www.birpublications.org/doi/10.1259/dmfr.20210197>
10. Chinnikatti SK. Artificial Intelligence in Forensic Science. *Forensic Sci Addict Res.* 2018 ;2(5).

11. Khanagar SB, Vishwanathaiah S, Naik S, A. Al-Kheraif A, Devang Divakar D, Sarode SC, et al. Application and performance of artificial intelligence technology in forensic odontology – A systematic review. *Leg Med* [Internet]. 2021;48. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1344622320301607>
12. Dawlidowicz-Basir I, Frankowski W, Hauser R. A review of investigational methods used in dentition based age determination problems of forensic sciences. *Problems of Forensic Sciences*. 2004; LVII:139–57.
13. Senn DR, Stimson PG. *Forensic dentistry*. CRC Press. 2010.
14. Afşin H. *Adli diş hekimliği*. İstanbul: Adli Tıp Kurumu Yayınları, Toprak Ofset; 2004.
15. Baransel Isır A, Buken B, Tokdemir M, Dülger H, Erel Ö, Fedakar R. 1998-2005 yılları arasında Türkiye’de 5 farklı bölgedeki üniversitelerin adli tıp anabilim dallarında raporlandırılan yaş tayini olgularının irdelenmesi. *Türkiye Klinikleri Adli Tıp Dergisi*. 2009;29(2):303–13.
16. Martrille L, Ubelaker DH, Cattaneo C, Seguret F, Tremblay M, Baccino E. Comparison of Four Skeletal Methods for the Estimation of Age at Death on White and Black Adults. *J Forensic Sci* [Internet]. 2007 ;52(2):302–7. Available from: <https://onlinelibrary.wiley.com/doi/10.1111/j.1556-4029.2006.00367.x>
17. Garn SM, Lewis AB, Kerewsky RS. Genetic, nutritional, and maturational correlates of dental development. *J Dent Res*. 1965; 44(1): 228–42.
18. Yaşar F, Afşin H, Hancı İH. *Adli diş hekimliği*. *TBB Dergisi*. 2004; 54: 351–4.
19. Eckert WG, Garland N. The history of the forensic application in radiology. *Am J Forensic Med Pathol* [Internet]. 1984; 5(1) :53–6. Available from: <http://journals.lww.com/00000433-198403000-00010>
20. Huda TFJ, Bowman JE. Age determination from dental microstructure in juveniles. *Am J Phys Anthropol* [Internet]. 1995;97(2):135–50. Available from: <https://onlinelibrary.wiley.com/doi/10.1002/ajpa.1330970206>

21. Noble HW. The estimation of age from the dentition. *Journal of the Forensic Science Society* [Internet]. 1974;14(3):215–21. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0015736874709045>
22. Graham EA. Economic, Racial, and cultural influences on the growth and maturation of children. *Pediatr Rev* [Internet]. 2005;26(8):290–4. Available from: <http://pedsinreview.aappublications.org/cgi/doi/10.1542/pir.26-8-290>
23. Schmeling A, Grundmann C, Fuhrmann A, Kaatsch HJ, Knell B, Ramsthaler F, et al. Criteria for age estimation in living individuals. *Int J Legal Med* [Internet]. 2008 ;122(6):457–60. Available from: <http://link.springer.com/10.1007/s00414-008-0254-2>
24. Sadler TW. *Langman’s medical embryology*. 12th ed. Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins; 2012.
25. Chiego DJ. *Essentials of oral histology and embryology : a clinical approach* [Internet]. St. Louis, Missouri: Elsevier; 2019. Available from: <http://evolve.elsevier.com/Chiego/oralhistology>
26. Massler M, Schour I. Studies in tooth development: Theories of eruption. *Am J Orthod Oral Surg* [Internet]. 1941 ;27(10):552–76. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0096634741904131>
27. Craddock HL, Youngson CC. Eruptive tooth movement — the current state of knowledge. *Br Dent J* [Internet]. 2004 ;197(7):385–91. Available from: <http://www.nature.com/articles/4811712>
28. Koch G, Poulsen S, Espelid I, Haubek D. *Pediatric dentistry: a clinical approach*. 3rd ed. Chichester, West Sussex, UK: John Wiley & Sons Inc.; 2017.
29. Ülgen M. *Ortodonti*. İstanbul: Ankara Üniversitesi Diş Hekimliği Fakültesi Yayınları; 2010.
30. Nowak AJ. *Pediatric dentistry: infancy through adolescence*. 6th ed. Philadelphia: Elsevier; 2019.

31. Sivakumar N, Usha K, Nirmala S. Dentin dysplasia type I with pyogenic granuloma in a 12-year-old girl. *Journal of Indian Society of Pedodontics and Preventive Dentistry* [Internet]. 2009;27(2):131. Available from: <http://www.jisppd.com/text.asp?2009/27/2/131/55343>
32. Kalk WWI, Batenburg RHK, Vissink A. Dentin dysplasia type I. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology* [Internet]. 1998 ;86(2):175–8. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1079210498901214>
33. Marks SC, Schroeder HE. Tooth eruption: theories and facts. *Anat Rec* [Internet]. 1996 ;245(2):374–93. Available from: [https://onlinelibrary.wiley.com/doi/10.1002/\(SICI\)1097-0185\(199606\)245:2<374::AID-AR18>3.0.CO;2-M](https://onlinelibrary.wiley.com/doi/10.1002/(SICI)1097-0185(199606)245:2<374::AID-AR18>3.0.CO;2-M)
34. Wise GE, King GJ. Mechanisms of Tooth Eruption and Orthodontic Tooth Movement. *J Dent Res* [Internet]. 2008 ;87(5):414–34. Available from: <http://journals.sagepub.com/doi/10.1177/154405910808700509>
35. Almonaitiene R, Balciuniene I, Tutkuvienė J. Factors influencing permanent teeth eruption. Part one--general factors. *Stomatologija* [Internet]. 2010;12(3):67–72. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/21063135>
36. Hacınlioğlu NM, Kavaloğlu Çıldır Ş. Çocuklarda kapanış ilişkileri ve oklüzyon. *Selcuk Dental Journal*. 2011;12(1):91–7.
37. Nanci A. Ten Cate's oral histology : development, structure, and function [Internet]. 9th ed. St. Louis: Elsevier; 2018. Available from: www.konkur.in
38. Schour I, Massler M. The development of the human dentition. *Journal of the American Dental Association*. 1941;28:1153–60.
39. Gleiser I, Hunt EE. The permanent mandibular first molar: Its calcification, eruption and decay. *Am J Phys Anthropol* [Internet]. 1955;13(2):253–83. Available from: <https://onlinelibrary.wiley.com/doi/10.1002/ajpa.1330130206>

40. Nolla CM. The development of the permanent teeth. *Journal of Dental Children*. 1960; 27: 254–66.
41. Moorrees CFA, Fanning EA, Hunt EE. Age variation of formation stages for ten permanent teeth. *J Dent Res*. 1963;42(6):1490–502.
42. Anderson DL, Thompson GW, Popovich F. Age of attainment of mineralization stages of the permanent dentition. *J Forensic Sci* [Internet]. 1976 ;21(1):191–200. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/1249551>
43. Mörnstad H, Staaf V, Welander U. Age estimation with the aid of tooth development: a new method based on objective measurements. *Eur J Oral Sci* [Internet]. 1994 ;102(3):137–43. Available from: <https://onlinelibrary.wiley.com/doi/10.1111/j.1600-0722.1994.tb01169.x>
44. Demirjian A, Goldstein H, Tanner JM. A new system of dental age assessment. *Hum Biol* [Internet]. 1973;45(2):211–27. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/4714564>
45. Cameriere R, Ferrante L, Cingolani M. Age estimation in children by measurement of open apices in teeth. *Int J Legal Med* [Internet]. 2006;120(1):49–52. Available from: <http://link.springer.com/10.1007/s00414-005-0047-9>
46. Gustafson G, Malmö DO. Age Determinations on Teeth. *The Journal of the American Dental Association* [Internet]. 1950;41(1):45–54. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0002817750110057>
47. Lamendin H, Baccino E, Humbert JF, Tavernier JC, Nossintchouk RM, Zerilli A. A simple technique for age estimation in adult corpses: the two criteria dental method. *J Forensic Sci* [Internet]. 1992;37(5):1373–9. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/1402761>
48. Molnar S. Human tooth wear, tooth function and cultural variability. *Am J Phys Anthropol* [Internet]. 1971 ;34(2):175–89. Available from: <https://onlinelibrary.wiley.com/doi/10.1002/ajpa.1330340204>

49. Ball J. A critique of age estimation using attrition as the sole indicator. *J Forensic Odontostomatol* [Internet]. 2002 ;20(2):38–42. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/12585672>
50. İşcan MY, Steyn M. *The human skeleton in forensic medicine*. 3rd ed. American Journal of Physical Anthropology. Springfield, Illinois: Charles C Thomas Publisher; 2013.
51. Nalbandian J, Gonzales F, Sognaes RF. Sclerotic age changes in root dentin of human teeth as observed by optical, electron, and x-ray microscopy. *J Dent Res* [Internet]. 1960 May 9;39(3):598–607. Available from: <http://journals.sagepub.com/doi/10.1177/00220345600390032101>
52. Bang G, Ramm E. Determination of age in humans from root dentin transparency. *Acta Odontol Scand* [Internet]. 1970 ;28(1):3–35. Available from: <http://www.tandfonline.com/doi/full/10.3109/00016357009033130>
53. Solheim T. Dental root translucency as an indicator of age. *Eur J Oral Sci* [Internet]. 1989 Jun;97(3):189–97. Available from: <https://onlinelibrary.wiley.com/doi/10.1111/j.1600-0722.1989.tb01602.x>
54. Afşin H. İskelet Kalıntılarında Dişlerden Yaş Tayininde Dentin Transparasyonu Görüntü Analizi Yöntemi. İ.Ü. Adli Tıp Enstitüsü, Doktora Tezi, 1999, İstanbul (Danışman: Prof. Dr. Sedat Çöloğlu.)
55. Solheim T. Dental cementum apposition as an indicator of age. *Scand J Dent Res*. 1990; 98:510–9.
56. Stott GG, Sis RF, Levy BM. Cemental annulation as an age criterion in forensic dentistry. *J Dent Res* [Internet]. 1982 ;61(6):814–7. Available from: <http://journals.sagepub.com/doi/10.1177/00220345820610063401>
57. Miller CS, Dove SB, Cottone JA. Failure of use of cemental annulations in teeth to determine the age of humans. *J Forensic Sci* [Internet]. 1988 ;33(1):137–43. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/3351451>

58. Renz H, Radlanski RJ. Incremental lines in root cementum of human teeth —A reliable age marker? *HOMO* [Internet]. 2006;57(1):29–50. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0018442X05000454>
59. Helfman PM, Bada JL. Aspartic acid racemization in tooth enamel from living humans. *Proceedings of the National Academy of Sciences* [Internet]. 1975;72(8):2891–4. Available from: <https://pnas.org/doi/full/10.1073/pnas.72.8.2891>
60. Ritz S, Schütz HW, Peper C. Postmortem estimation of age at death based on aspartic acid racemization in dentin: Its applicability for root dentin. *Int J Legal Med* [Internet]. 1993;105(5):289–93. Available from: <http://link.springer.com/10.1007/BF01370387>
61. Benešová T, Honzátko A, Pilin A, Votruba J, Flieger M. A modified HPLC method for the determination of aspartic acid racemization in collagen from human dentin and its comparison with GC. *J Sep Sci* [Internet]. 2004 ;27(4):330–4. Available from: <https://onlinelibrary.wiley.com/doi/10.1002/jssc.200301681>
62. Carolan VA, Gardner ML, Lucy D, Pollard AM. Some considerations regarding the use of amino acid racemization in human dentine as an indicator of age at death. *J Forensic Sci* [Internet]. 1997;42(1):10–6. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/8988569>
63. Waite ER, Collins MJ, Ritz-Timme S, Schutz HW, Cattaneo C, Borrman HIM. A review of the methodological aspects of aspartic acid racemization analysis for use in forensic science. *Forensic Sci Int* [Internet]. 1999;103(2):113–24. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S037907389900081X>
64. Spalding KL, Buchholz BA, Bergman LE, Druid H, Frisén J. Age written in teeth by nuclear tests. *Nature* [Internet]. 2005 ;437(7057):333–4. Available from: <http://www.nature.com/articles/437333a>
65. Ren F, Li C, Xi H, Wen Y, Huang K. Estimation of Human Age According to Telomere Shortening in Peripheral Blood Leukocytes of Tibetan. *American Journal of Forensic Medicine & Pathology*. 2009 ;30(3):252–5.

66. Johnson FB, Sinclair DA, Guarente L. Molecular Biology of Aging. Cell [Internet]. 1999;96(2):291–302. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S009286740080567X>
67. Takasaki T, Tsuji A, Ikeda N, Ohishi M. Age estimation in dental pulp DNA based on human telomere shortening. Int J Legal Med [Internet]. 2003;117(4):232–4. Available from: <http://link.springer.com/10.1007/s00414-003-0376-5>
68. Woods MA, Robinson QC, Harris EF. Age-Progressive Changes in Pulp Widths and Root Lengths During Adulthood: A Study of American Blacks and Whites. Gerodontology. 1990;9(1–3):41–50.
69. Kvaal SI, Kolltveit KM, Thomsen IO, Solheim T. Age estimation of adults from dental radiographs. Forensic Sci Int [Internet]. 1995;74(3):175–85. Available from: <https://linkinghub.elsevier.com/retrieve/pii/037907389501760G>
70. Cameriere R, Ferrante L, Cingolani M. Variations in pulp/tooth area ratio as an indicator of age: a preliminary study. J Forensic Sci. 2004;49(2):317–9.
71. Martin-de las Heras S, Valenzuela A, Bellini R, Salas C, Rubiño M, Garcia JA. Objective measurement of dental color for age estimation by spectroradiometry. Forensic Sci Int. 2003;132(1):57–62.
72. Lackovic KP, Wood RE. Tooth root colour as a measure of chronological age. J Forensic Odontostomatol. 2000 Dec;18(2):37–45.
73. Solheim T. Dental color as an indicator of age. Gerodontology. 1988 ;4(3):114–8.
74. Kvaal SI, Koppang HS, Solheim T. Relationship between age and deposit of peritubular dentine. Gerodontology. 1994 ;11(2):93–8.
75. Amariti ML, Restori M, De Ferrari F, Paganelli C, Faglia R, Legnani G. A histological procedure to determine dental age. J Forensic Odontostomatol. 2000 ;18(1):1–5.
76. Drusini AG. Age estimation from teeth using soft X-ray findings. Anthropol Anz. 1993;51(1):41–6.

77. Drusini AG, Toso O, Ranzato C. The coronal pulp cavity index: A biomarker for age determination in human adults. *Am J Phys Anthropol.* 1997 ;103(3):353–63.
78. Philippas GG, Applebaum E. Age Change in the Permanent Upper Canine Teeth. *J Dent Res* [Internet]. 1968 ;47(3):411–7. Available from: <http://journals.sagepub.com/doi/10.1177/00220345680470031201>
79. Morse DR. Age-related changes of the dental pulp complex and their relationship to systemic aging. *Oral Surgery, Oral Medicine, Oral Pathology.* 1991;72(6):721–45.
80. Vandervoort FM, Bergmans L, Van Cleynenbreugel J, Bielen DJ, Lambrechts P, Wevers M, et al. Age calculation using X-ray microfocus computed tomographical scanning of teeth: a pilot study. *J Forensic Sci.* 2004 ;49(4):787–90.
81. Someda H, Saka H, Matsunaga S, Ide Y, Nakahara K, Hirata S, et al. Age estimation based on three-dimensional measurement of mandibular central incisors in Japanese. *Forensic Sci Int.* 2009;185(1–3):110–4.
82. Aboshi H, Takahashi T, Komuro T. Age estimation using microfocus X-ray computed tomography of lower premolars. *Forensic Sci Int.* 2010;200(1–3):35–40.
83. Yang F, Jacobs R, Willems G. Dental age estimation through volume matching of teeth imaged by cone-beam CT. *Forensic Sci Int.* 2006 ;159(1).
84. Pinchi V, Pradella F, Buti J, Baldinotti C, Focardi M, Norelli GA. A new age estimation procedure based on the 3D CBCT study of the pulp cavity and hard tissues of the teeth for forensic purposes: A pilot study. *J Forensic Leg Med.* 2015; 36:150–7.
85. Harorlı A. Ağız, Diş ve Çene Radyolojisi [Internet]. Nobel Tıp Kitabevi; 2014. Available from: www.nobeltip.com
86. Mallya S, Lam E. *White and Pharoah's oral radiology : principles and interpretation.* 8th ed. St. Louis, Missouri: Elsevier; 2019.
87. Rhodes JS, Ford TRP, Lynch JA, Liepins PJ, Curtis R V. Micro-computed tomography: a new tool for experimental endodontology. *Int Endod J* [Internet]. 1999;32(3):165–70. Available from: <https://onlinelibrary.wiley.com/doi/abs/10.1046/j.1365-2591.1999.00204.x>

88. Swain M V, Xue J. State of the Art of Micro-CT Applications in Dental Research. *Int J Oral Sci* [Internet]. 2009;1(4):177–88. Available from: <http://www.nature.com/ijos/journal/v1/n4/abs/ijos200924a.html>
89. Peters OA, Laib A, Rügsegger P, Barbakow F. Three-dimensional Analysis of Root Canal Geometry by High-resolution Computed Tomography. *J Dent Res* [Internet]. 2000;79(6):1405–9. Available from: <http://journals.sagepub.com/doi/10.1177/00220345000790060901>
90. Maret D, Molinier F, Braga J, Peters OA, Telmon N, Treil J, et al. Accuracy of 3D Reconstructions Based on Cone Beam Computed Tomography. *J Dent Res* [Internet]. 2010;89(12):1465–9. Available from: <http://journals.sagepub.com/doi/10.1177/0022034510378011>
91. Scarfe WC, Farman AG. What is Cone-Beam CT and How Does it Work? *Dent Clin North Am* [Internet]. 2008;52(4):707–30. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S001185320800044X>
92. Uğur A, Kınacı AC. Yapay Zeka Teknikleri ve Yapay Sinir Ağları Kullanılarak Web Sayfalarının Sınıflandırılması. XI Türkiye’de İnternet Konferansı Bildirileri. 2006.
93. Öztürk K, Şahin ME. A General View of Artificial Neural Networks and Artificial Intelligence [Internet]. 2018;6(2):25–36. Available from: <http://www.sloi.org/sloi-name-of-this-article>
94. Dore F. Güçlü yapay zekaya karşı Çin odası argümanı. *Afyon Kocatepe Üniversitesi Sosyal Bilimler Dergisi*. 2012;14(1):23–8.
95. Bahrammirzaee A. A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Comput Appl* [Internet]. 2010 Nov 20;19(8):1165–95. Available from: <http://link.springer.com/10.1007/s00521-010-0362-z>
96. Michalewicz Z, Schoenauer M. Evolutionary Algorithms for Constrained Parameter Optimization Problems. *Evol Comput*. 1996;4(1):1–32.
97. Mathew T V. *Genetic Algorithm*. Bombay; 2012.

98. Öztemel E. Yapay sinir ağları. İstanbul: Papatya Yayıncılık; 2006.
99. Bishop CM. Neural networks for pattern recognition. Cambridge: Oxford University Press; 1995.
100. Rumelhart DE, Hinton GE, Williams RJ. Learning internal representations by error propagation. Bradford Books/MIT Press; 1985.
101. Sapci AH, Sapci HA. Artificial Intelligence Education and Tools for Medical and Health Informatics Students: Systematic Review. JMIR Med Educ [Internet]. 2020 ;6(1). Available from: <http://mededu.jmir.org/2020/1/e19285/>
102. Johnson KW, Torres Soto J, Glicksberg BS, Shameer K, Miotto R, Ali M, et al. Artificial Intelligence in Cardiology. J Am Coll Cardiol [Internet]. 2018 ;71(23):2668–79. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0735109718344085>
103. Zhang XD. A Matrix Algebra Approach to Artificial Intelligence [Internet]. Singapore: Springer Singapore; 2020. Available from: <http://link.springer.com/10.1007/978-981-15-2770-8>
104. Fyfe C. Artificial neural networks and information theory. 1.2. The university of Paisley; 2000.
105. Ng A. Generative learning algorithms. Stanford Lecture Notes 5.4. 2008.
106. Yılmaz A. Yapay zeka. İstanbul: KODLAB Yayın Dağıtım Yazılım Ltd. Şti.; 2021.
107. Raschka S, Mirjalili V. Python machine learning : machine learning and deep learning with python, scikit-learn, and tensorflow 2. 2nd ed. Birmingham: Packt Publishing Ltd; 2019.
108. Russell R. Machine Learning: Step-by-Step Guide To Implement Machine Learning Algorithms with Python. CreateSpace Independent Publishing Platform; 2018.
109. Deng L. Deep Learning: Methods and Applications. Foundations and Trends in Signal Processing [Internet]. 2014;7(3–4):197–387. Available from: <http://nowpublishers.com/articles/foundations-and-trends-in-signal-processing/SIG-039>

110. Alpaydın E. Yapay zeka. İstanbul: Türkmenler Matbaacılık Reklam San. ve Tic. Ltd. Şti.; 2021.
111. Chermiti B. Establishing risk and targeting profiles using data mining: Decision trees. *World Customs Journal*. 2019;13(2):39–58.
112. Li M, Xu H, Deng Y. Evidential Decision Tree Based on Belief Entropy. *Entropy* [Internet]. 2019 Sep 16;21(9):897. Available from: <https://www.mdpi.com/1099-4300/21/9/897>
113. Song YY, Lu Y. Decision tree methods: applications for classification and prediction. *Shanghai Arch Psychiatry*. 2015 Apr 25;27(2):130–5.
114. Goodfellow I, Bengio Y, Courville A. *Deep learning*. MIT Press; 2016.
115. Marcus G. *Deep Learning: A Critical Appraisal*. arXiv preprint arXiv:1801.00631. 2018.
116. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015 May 28;521(7553):436–44.
117. Tamura S, Tateishi M. Capabilities of a four-layered feedforward neural network: four layers versus three. *IEEE Trans Neural Netw*. 1997 Mar;8(2):251–5.
118. İnik Ö, Ülker B A Bilgisayar E, Bölümü M, Üniversitesi G, Üniversitesi S, Konya T, et al. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Journal of Scientific Research* [Internet]. Available from: <http://dergipark.gov.tr/gbad>
119. Doğan F, Türkoğlu İ. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *DÜMF Mühendislik Dergisi*. 2019 ;10(2):409–45.
120. Cireşan DCC, Meier U, Masci J, Gambardella LM, Urgan Schmidhuber J. Flexible, High Performance Convolutional Neural Networks for Image Classification. *Twenty-second international joint conference on artificial intelligence*. 2011.
121. Pang Y, Sun M, Jiang X, Li X. Convolution in convolution for network in network. *IEEE Trans Neural Netw Learn Syst*. 2018 ;29(5):1587–97.

122. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Commun ACM*. 2017 ;60(6):84–90.
123. Hinton G. A Practical Guide to Training Restricted Boltzmann Machines [Internet]. 2010. Available from: <http://learning.cs.toronto.edu>
124. Zeiler MD, Fergus R. Stochastic Pooling for Regularization of Deep Convolutional Neural Networks. 2013.
125. Lin M, Chen Q, Yan S. Network In Network. *arXiv preprint arXiv:1312.4400*. 2013.
126. Srivastava N, Hinton G, Krizhevsky A, Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*. 2014; 15.
127. Tang Y. Deep Learning using Linear Support Vector Machines. *arXiv preprint arXiv:1306.0239*. 2013.
128. Li H, Lin Z, Shen X, Brandt J, Hua G. A Convolutional Neural Network Cascade for Face Detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015.
129. Ioffe S, Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *International conference on machine learning*. pmlr, 2015
130. Sunali D, Khanna S, Dhaimade PA, Khanna S. Artificial Intelligence: Transforming Dentistry Today. *Indian Journal of Basic and Applied Medical Research [Internet]*. 2017;(6):161–7. Available from: www.ijbamr.com
131. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nat Rev Cancer*. 2018 ;18(8):500–10.
132. Joda T, Yeung AWK, Hung K, Zitzmann NU, Bornstein MM. Disruptive Innovation in Dentistry: What It Is and What Could Be Next. *J Dent Res*. 2021 ;100(5):448–53.
133. Geetha V, Aprameya KS, Hinduja DM. Dental caries diagnosis in digital radiographs using back-propagation neural network. *Health Inf Sci Syst*. 2020 ;8(1):8.

134. Devito KL, de Souza Barbosa F, Filho WNF. An artificial multilayer perceptron neural network for diagnosis of proximal dental caries. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*. 2008 ;106(6):879–84.
135. Yu Y, Li Y, Li Y jing, Wang J ming, Lin D hui, Ye W ping. Tooth Decay Diagnosis using Back Propagation Neural Network. *2006 International Conference on Machine Learning and Cybernetics*. IEEE; 2006: 3956–9.
136. Li W, Kuang W, Li Y, Li YJ, Ye WP. Clinical X-Ray Image Based Tooth Decay Diagnosis using SVM. *2007 International Conference on Machine Learning and Cybernetics*. IEEE; 2007: 1616–9.
137. Ramzi Ben A, Ejbali R, Zaied M. Detection and Classification of Dental Caries in X-ray Images Using Deep Neural Networks. *International conference on software engineering advances (ICSEA)*. 2016
138. Singh P, Sehgal P. Automated caries detection based on Radon transformation and DCT. *2017 8th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*. IEEE; 2017: 1–6.
139. Choi J, Eun H, Kim C. Boosting Proximal Dental Caries Detection via Combination of Variational Methods and Convolutional Neural Network. *J Signal Process Syst*. 2018 ;90(1):87–97.
140. Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent*. 2018; 77:106–11.
141. Endres MG, Hillen F, Salloumis M, Sedaghat AR, Niehues SM, Quatela O, et al. Development of a Deep Learning Algorithm for Periapical Disease Detection in Dental Radiographs. *Diagnostics*. 2020 ;10(6):430.
142. Mol A, van der Stelt PF. Application of computer-aided image interpretation to the diagnosis of periapical bone lesions. *Dentomaxillofacial Radiology*. 1992 ;21(4):190–4.

143. Flores A, Rysavy S, Enciso R, Okada K. Non-invasive differential diagnosis of dental periapical lesions in cone-beam CT. 2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro. IEEE; 2009: 566–9.
144. Okada K, Rysavy S, Flores A, Linguraru MG. Noninvasive differential diagnosis of dental periapical lesions in cone-beam CT scans. *Med Phys*. 2015 ;42(4):1653–65.
145. Lin PL, Huang PY, Huang PW. Automatic methods for alveolar bone loss degree measurement in periodontitis periapical radiographs. *Comput Methods Programs Biomed*. 2017; 148:1–11.
146. Lin PL, Huang PW, Huang PY, Hsu HC. 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. *Comput Methods Programs Biomed*. 2015;121(3):117–26.
147. Mikulka J, Gescheidtová E, Kabrda M, Peřina V. Classification of Jaw Bone Cysts and Necrosis via the Processing of Orthopantomograms. *Radioengineering*. 2013;22(1):114-122.
148. Nurtanio I. Classifying Cyst and Tumor Lesion Using Support Vector Machine Based on Dental Panoramic Images Texture Features [Internet]. Article in IAENG International Journal of Computer Science. 2013. Available from: <https://www.researchgate.net/publication/287165581>
149. Yilmaz E, Kayikcioglu T, Kayipmaz S. Computer-aided diagnosis of periapical cyst and keratocystic odontogenic tumor on cone beam computed tomography. *Comput Methods Programs Biomed*. 2017;146:91–100.
150. Poedjiastoeti W, Suebnukarn S. Application of Convolutional Neural Network in the Diagnosis of Jaw Tumors. *Healthc Inform Res*. 2018;24(3):236.
151. Ariji Y, Yanashita Y, Kutsuna S, Muramatsu C, Fukuda M, Kise Y, et al. Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2019;128(4):424–30.

152. Watanabe H, Arijji Y, Fukuda M, Kuwada C, Kise Y, Nozawa M, et al. Deep learning object detection of maxillary cyst-like lesions on panoramic radiographs: preliminary study. *Oral Radiol.* 2021 ;37(3):487–93.
153. Lee J, Kim D, Jeong S. Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. *Oral Dis.* 2020; 26(1):152–8.
154. Yu HJ, Cho SR, Kim MJ, Kim WH, Kim JW, Choi J. Automated skeletal classification with lateral cephalometry based on artificial intelligence. *J Dent Res.* 2020 ;99(3):249–56.
155. Park JH, Hwang HW, Moon JH, Yu Y, Kim H, Her SB, et al. Automated identification of cephalometric landmarks: Part 1- Comparisons between the latest deep-learning methods YOLOV3 and SSD. *Angle Orthod.* 2019 ;89(6):903–9.
156. Gupta A, Kharbanda OP, Sardana V, Balachandran R, Sardana HK. Accuracy of 3D cephalometric measurements based on an automatic knowledge-based landmark detection algorithm. *Int J Comput Assist Radiol Surg.* 2016 ;11(7):1297–309.
157. Gupta A, Kharbanda OP, Sardana V, Balachandran R, Sardana HK. A knowledge-based algorithm for automatic detection of cephalometric landmarks on CBCT images. *Int J Comput Assist Radiol Surg.* 2015; 10(11):1737–52.
158. Chu P, Bo C, Liang X, Yang J, Megalooikonomou V, Yang F, et al. Using Octuplet Siamese Network For Osteoporosis Analysis On Dental Panoramic Radiographs. 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). *IEEE*; 2018: 2579–82.
159. Lee KS, Jung SK, Ryu JJ, Shin SW, Choi J. Evaluation of transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs. *J Clin Med.* 2020 ;9(2):392.
160. Lee JS, Adhikari S, Liu L, Jeong HG, Kim H, Yoon SJ. Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminary study. *Dentomaxillofacial Radiology.* 2019 ;48(1):20170344.

161. Du X, Chen Y, Zhao J, Xi Y. A Convolutional Neural Network Based Auto-Positioning Method For Dental Arch In Rotational Panoramic Radiography. 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE; 2018: 2615–8.
162. Liang K, Zhang L, Yang H, Yang Y, Chen Z, Xing Y. Metal artifact reduction for practical dental computed tomography by improving interpolation-based reconstruction with deep learning. *Med Phys*. 2019 ;46(12).
163. Minnema J, Eijnatten M, Hendriksen AA, Liberton N, Pelt DM, Batenburg KJ, et al. Segmentation of dental cone-beam CT scans affected by metal artifacts using a mixed-scale dense convolutional neural network. *Med Phys*. 2019 ;46(11):5027–35.
164. Hegazy MAA, Cho MH, Cho MH, Lee SY. U-net based metal segmentation on projection domain for metal artifact reduction in dental CT. *Biomed Eng Lett*. 2019 ;9(3):375–85.
165. Prajapati SA, Nagaraj R, Mitra S. Classification of dental diseases using CNN and transfer learning. 5th International Symposium on Computational and Business Intelligence (ISCBI). IEEE; 2017: 70–4.
166. Murata M, Ariji Y, Ohashi Y, Kawai T, Fukuda M, Funakoshi T, et al. Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral Radiol*. 2019 ;35(3):301–7.
167. Kuwana R, Ariji Y, Fukuda M, Kise Y, Nozawa M, Kuwada C, et al. Performance of deep learning object detection technology in the detection and diagnosis of maxillary sinus lesions on panoramic radiographs. *Dentomaxillofac Radiol*. 2021;50(1):20200171.
168. Kim Y, Lee KJ, Sunwoo L, Choi D, Nam CM, Cho J, et al. Deep Learning in Diagnosis of Maxillary Sinusitis Using Conventional Radiography. *Invest Radiol*. 2019;54(1):7–15.
169. Kann BH, Aneja S, Loganadane G V., Kelly JR, Smith SM, Decker RH, et al. Pretreatment Identification of Head and Neck Cancer Nodal Metastasis and Extranodal Extension Using Deep Learning Neural Networks. *Sci Rep*. 2018 Sep 19;8(1):14036.

170. Arijji Y, Fukuda M, Kise Y, Nozawa M, Yanashita Y, Fujita H, et al. Contrast-enhanced computed tomography image assessment of cervical lymph node metastasis in patients with oral cancer by using a deep learning system of artificial intelligence. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2019;127(5):458–63.
171. Vinayahalingam S, Xi T, Bergé S, Maal T, de Jong G. Automated detection of third molars and mandibular nerve by deep learning. *Sci Rep.* 2019;9(1):9007.
172. Fukuda M, Arijji Y, Kise Y, Nozawa M, Kuwada C, Funakoshi T, et al. Comparison of 3 deep learning neural networks for classifying the relationship between the mandibular third molar and the mandibular canal on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020;130(3):336–43.
173. Jaskari J, Sahlsten J, Järnstedt J, Mehtonen H, Karhu K, Sundqvist O, et al. Deep Learning Method for Mandibular Canal Segmentation in Dental Cone Beam Computed Tomography Volumes. *Sci Rep.* 2020;10(1):5842.
174. Kwak GH, Kwak EJ, Song JM, Park HR, Jung YH, Cho BH, et al. Automatic mandibular canal detection using a deep convolutional neural network. *Sci Rep.* 2020;10(1):5711.
175. Vranckx M, Van Gerven A, Willems H, Vandemeulebroucke A, Ferreira Leite A, Politis C, et al. Artificial Intelligence (AI)-Driven Molar Angulation Measurements to Predict Third Molar Eruption on Panoramic Radiographs. *Int J Environ Res Public Health.* 2020 ;17(10):3716.
176. Orhan K, Bilgir E, Bayrakdar IS, Ezhov M, Gusarev M, Shumilov E. Evaluation of artificial intelligence for detecting impacted third molars on cone-beam computed tomography scans. *J Stomatol Oral Maxillofac Surg.* 2021;122(4):333–7.
177. Johari M, Esmaeili F, Andalib A, Garjani S, Saberkari H. Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an *ex vivo* study. *Dentomaxillofacial Radiology.* 2017 Feb;46(2):20160107.

178. Fukuda M, Inamoto K, Shibata N, Ariji Y, Yanashita Y, Kutsuna S, et al. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiol.* 2020;36(4):337–43.
179. Kuwada C, Ariji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, et al. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020;130(4):464–9.
180. Kise Y, Ikeda H, Fujii T, Fukuda M, Ariji Y, Fujita H, et al. Preliminary study on the application of deep learning system to diagnosis of Sjögren’s syndrome on CT images. *Dentomaxillofac Radiol.* 2019 Sep;48(6):20190019.
181. Shen D, Wu G, Suk HI. Deep Learning in Medical Image Analysis. *Annu Rev Biomed Eng.* 2017;19(1):221–48.
182. Kiranyaz S, Avci O, Abdeljaber O, Ince T, Gabbouj M, Inman DJ. 1D convolutional neural networks and applications: A survey. *Mech Syst Signal Process.* 2021;151.
183. Li X, Lu R, Wang Q, Wang J, Duan X, Sun Y, et al. One-dimensional convolutional neural network (1D-CNN) image reconstruction for electrical impedance tomography. *Review of Scientific Instruments.* 2020;91(12):124704.
184. Rala Cordeiro J, Raimundo A, Postolache O, Sebastião P. Neural architecture search for 1d CNNs—different approaches tests and measurements. *Sensors.* 2021;21(23):7990.
185. Mitchell TM. *Machine Learning*: 1997.
186. Araujo A, Norris W, Sim J. Computing receptive fields of convolutional neural networks. *Distill.* 2019;4(11).
187. Zhang L, Alharbe NR, Luo G, Yao Z, Li Y. A hybrid forecasting framework based on support vector regression with a modified genetic algorithm and a random forest for traffic flow prediction. *Tsinghua Sci Technol.* 2018;23(4):479–92.

188. Zhang L, Alharbe NR, Luo G, Yao Z, Li Y. A hybrid forecasting framework based on support vector regression with a modified genetic algorithm and a random forest for traffic flow prediction. *Tsinghua Sci Technol.* 2018;23(4):479–92.
189. Breiman L. Random forests. *Mach Learn.* 2001;45(1):5–32.
190. Bektas B, Babur S. Machine learning based performance development for diagnosis of breast cancer. *Medical Technologies National Congress (TIPTEKNO). IEEE;* 2016: 1–4.
191. Chang Wook Ahn, Ramakrishna RS. Elitism-based compact genetic algorithms. *IEEE Transactions on Evolutionary Computation.* 2003 ;7(4):367–85.
192. Irmak S. Veri Madenciliği Yöntemleri ile Sağlık Sektörü Veritabanlarında Bilgi Keşfi: Tanımlayıcı ve Kestirimci Model Uygulamaları. Akdeniz Üniversitesi Sosyal Bilimler Enstitüsü Doktora Tezi, 2009, Antalya (Danışman: Doç. Dr. Can Deniz KÖKSAL).
193. Demircan Kutluay T, Eken S. Keşifsel veri analizi kullanarak vakum şarj test süresinin azaltılması. *Acta Infologica.* 2021 ;5(1):187–96.
194. Karasu S, Altan A, Sarac Z, Hacioglu R. Prediction of Bitcoin prices with machine learning methods using time series data. *26th Signal Processing and Communications Applications Conference (SIU). IEEE;* 2018: 1–4.
195. Han M, Du S, Ge Y, Zhang D, Chi Y, Long H, et al. With or without human interference for precise age estimation based on machine learning? *Int J Legal Med.* 2022;136(3):821–31.
196. Apaydin BK, Yasar F. Accuracy of the demirjian, willems and cameriere methods of estimating dental age on Turkish children. *Niger J Clin Pract.* 2018 ;21(3):257–63.
197. Shamim T. Forensic pediatric dentistry. *J Forensic Dent Sci.* 2018;10(3):128.
198. 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. *Comput Biol Med.* 2022;149.

199. Galibourg A, Cussat-Blanc S, Dumoncel J, Telmon N, Monsarrat P, Maret D. Comparison of different machine learning approaches to predict dental age using Demirjian's staging approach [Internet]. Available from: <https://doi.org/10.1007/s00414-020-02489-5>
200. Kapoor P, Jain V. Comprehensive Chart for Dental Age Estimation (DAEcc8) based on Demirjian 8-teeth method: Simplified for operator ease. *J Forensic Leg Med.* 2018; 59:45–9.
201. Moness Ali AM, Ahmed WH, Khattab NM. Applicability of Demirjian's method for dental age estimation in a group of Egyptian children. *BDJ Open.* 2019 Dec 1;5(1).
202. Yang Z, Geng K, Liu Y, Sun S, Wen D, Xiao J, et al. Accuracy of the Demirjian and Willems methods of dental age estimation for children from central southern China. *Int J Legal Med.* 2019 ;133(2):593–601.
203. Prasad H, Kala N. Accuracy of two dental age estimation methods in the Indian population - A meta-analysis of published studies. *J Forensic Odontostomatol* [Internet]. 2019 ;3(37):2–11. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/31894132>
204. Esan TA, Yengopal V, Schepartz LA. The Demirjian versus the Willems method for dental age estimation in different populations: A meta-analysis of published studies. *PLoS One.* 2017;12(11).
205. Tunc E Sen, Koyuturk AE. Dental age assessment using Demirjian's method on northern Turkish children. *Forensic Sci Int.* 2008;175(1):23–6.
206. Liversidge HM, Speechly T, Hector MP. Dental maturation in British children: are Demirjian's standards applicable? *Int J Paediatr Dent.* 1999;9(4):263–9.
207. Celikoglu M, Cantekin K, Ceylan I. Dental Age Assessment: The Applicability of Demirjian Method in Eastern Turkish Children. *J Forensic Sci.* 2011;56.
208. Pinar Erdem A, Yamac E, Erdem MA, Sepet E, Aytepe Z. A new method to estimate dental age. *Acta Odontol Scand.* 2013;71(3–4):590–8.

209. Celik S, Zeren C, Çelikel A, Yengil E, Altan A. Applicability of the Demirjian method for dental assessment of southern Turkish children. *J Forensic Leg Med.* 2014; 25:1–5.
210. Erken Gungor O, Kale B, Celikoglu M, Gungor AY, Sari Z. Validity of the Demirjian method for dental age estimation for Southern Turkish children. *Niger J Clin Pract.* 2015 ;18(5):616–9.
211. Altunsoy M, Nur BG, Akkemik O, Ok E, Evcil MS. Applicability of the Demirjian method for dental age estimation in western Turkish children. *Acta Odontol Scand.* 2014 ;73(2):121–5.
212. Koç A, Özlek E, Gül A, Talmaç Ö. Accuracy of the London atlas, Willems, and Nolla methods for dental age estimation: a cross-sectional study on Eastern Turkish children [Internet]. Available from: <https://www.qmul.ac.uk/dentistry/atlas/software-app/>
213. Onat Altan H, Altan A, Bilgiç F, Akinci Sözer Ö, Damlar I. The applicability of Willems’ method for age estimation in southern Turkish children: A preliminary study. *J Forensic Leg Med.* 2016; 38:24–7.
214. Nur B, Kusgoz A, Bayram M, Celikoglu M, Nur M, Kayipmaz S, et al. Validity of demirjian and nolla methods for dental age estimation for Northeastern Turkish children aged 5-16 years old. *Med Oral Patol Oral Cir Bucal.* 2012 ;17(5).
215. Ozveren N, Serindere G, Meric P, Cameriere R. A comparison of the accuracy of Willems’ and Cameriere’s methods based on panoramic radiography. *Forensic Sci Int.* 2019;302.
216. Tao J, Wang J, Wang A, Xie Z, Wang Z, Wu S, et al. Dental Age Estimation: A Machine Learning Perspective. *Advances in Intelligent Systems and Computing.* Springer Verlag; 2020:722–33.
217. Shen S, Liu Z, Wang J, Fan L, Ji F, Tao J. Machine learning assisted Cameriere method for dental age estimation. *BMC Oral Health.* 2021 ;21(1).
218. 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. *J Forensic Odontostomatol* [Internet]. 2017 ;35(2):42–54. Available from: <http://www.ncbi.nlm.nih.gov/pubmed/29384736>

219. Merdietio Boedi R, Banar N, De Tobel J, Bertels J, Vandermeulen D, Thevissen PW. Effect of Lower Third Molar Segmentations on Automated Tooth Development Staging using a Convolutional Neural Network. *J Forensic Sci.* 2020 ;65(2):481–6.
220. Banar N, Bertels J, Laurent F, Boedi RM, De Tobel J, Thevissen P, et al. Towards fully automated third molar development staging in panoramic radiographs. *Int J Legal Med.* 2020;134(5):1831–41.
221. Kim S, Lee YH, Noh YK, Park FC, Auh QS. Age-group determination of living individuals using first molar images based on artificial intelligence. *Sci Rep.* 2021;11(1).
222. Guo Y cheng, Han M, Chi Y, Long H, Zhang D, Yang J, et al. Accurate age classification using manual method and deep convolutional neural network based on orthopantomogram images. *Int J Legal Med* [Internet]. 2021 Jul 4;135(4):1589–97. Available from: <https://link.springer.com/10.1007/s00414-021-02542-x>
223. Cular L, Tomaic M, Subasic M, Saric T, Sajkovic V, Vodanovic M. Dental age estimation from panoramic X-ray images using statistical models. *International Symposium on Image and Signal Processing and Analysis, ISPA.* IEEE Computer Society; 2017: 25–30.
224. De Back W, Seurig S, Wagner S, Marré B, Roeder I, Scherf N. Forensic age estimation with Bayesian convolutional neural networks based on panoramic dental X-ray imaging. *Proceedings of Machine Learning Research.* 2019
225. Wallraff S, Vesal S, Syben C, Lutz R, Maier A. Age Estimation on Panoramic Dental X-ray Images using Deep Learning. *Informatik Aktuell.* Springer Science and Business Media Deutschland GmbH; 2021: 186–91.
226. Sharifonnasabi F, Jhanjhi NZ, John J, Obeidy P, Band SS, Alinejad-Rokny H, et al. Hybrid HCNN-KNN Model Enhances Age Estimation Accuracy in Orthopantomography. *Front Public Health.* 2022 May 30;10.

EKLER

Ek 1. ETİK KURUL ONAY FORMU

Evrak Tarih ve Sayısı: 05.05.2022-E.202083



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

Sayı : E-60116787-020-202083
Konu : Başvurunuz Hk.

Sayın Doç. Dr. Burak Kerem APAYDIN

İlgi : 21/04/2022 tarihli dilekçeniz. 5.47.70.22
37168
11.05.2022

İlgi dilekçe ile başvurmuş olduğunuz **"Yapay Zeka Algoritmaları Kullanılarak Panoramik Radyograflar Üzerinden Bireylerin Diş Yaşlarının Tespiti"** konulu çalışmanız **26.04.2022 tarih ve 07 sayılı** kurul toplantımızda görüşülmüş olup,

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

Bilgilerinizi rica ederim.

Prof. Dr. Tahir TURAN
Başkan



Ek 2. ÖZGEÇMİŞ

[Redacted]

[Redacted]	[Redacted]	[Redacted]	[Redacted]
[Redacted]	[Redacted]	[Redacted]	[Redacted]
[Redacted]	[Redacted]	[Redacted]	[Redacted]

[Redacted]

[Redacted]	[Redacted]	[Redacted]
[Redacted]	[Redacted]	[Redacted]
[Redacted]	[Redacted]	[Redacted]
[Redacted]	[Redacted]	[Redacted]

[Redacted]

[Redacted]	[Redacted]	[Redacted]
[Redacted]	[Redacted]	[Redacted]

[Redacted]	[Redacted]	[Redacted]
[Redacted]	[Redacted]	[Redacted]

[Redacted]

[Redacted]	[Redacted]	[Redacted]	[Redacted]
[Redacted]	[Redacted]	[Redacted]	[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[Redacted]

[REDACTED]