

ORTODONTİDE YAPAY ZEKÂ

(Teori, Klinik Uygulamalar ve Gelecek Perspektifleri)

Doç. Dr. Ersin YILDIRIM




İKSAD
Publishing House

ORTODONTİDE YAPAY ZEKÂ

(Teori, Klinik Uygulamalar ve Gelecek Perspektifleri)

Doç. Dr. Ersin YILDIRIM

DOI: <https://www.doi.org/10.5281/zenodo.18249313>



Copyright © 2026 by iksad publishing house
All rights reserved. No part of this publication may be reproduced, distributed or
transmitted in any form or by
any means, including photocopying, recording or other electronic or mechanical
methods, without the prior written permission of the publisher, except in the case of
brief quotations embodied in critical reviews and certain other noncommercial uses
permitted by copyright law. Institution of Economic Development and Social
Researches Publications®

(The Licence Number of Pubicator: 2014/31220)

TÜRKİYE TR: +90 342 606 06 75

USA: +1 631 685 0 853

E mail: iksadyayinevi@gmail.com

www.iksadyayinevi.com

It is responsibility of the author to abide by the publishing ethics rules.

Iksad Publications – 2026©

ISBN: 978-625-378-572-7

Cover Design: İbrahim KAYA

January / 2026

Ankara / Türkiye

Size: 16x24cm

İÇİNDEKİLER

ÖNSÖZ.....	5
KISALTMALAR LİSTESİ	8
YAPAY ZEKÂ TERİMLERİ SÖZLÜĞÜ	9
1. GİRİŞ.....	11
2. GENEL BİLGİLER	15
2.1. Yapay Zekânın Ortodontiye Girişi ve Dijital Dönüşüm.....	15
2.1.1. Dijital Ortodontinin Evrimi	15
2.1.2. Yapay Zekânın Ortodontik Veriye Uygunluğu	17
2.1.3. AI Tabanlı Karar Destek Sistemleri Kavramı	18
2.2. Ortodontide Yapay Zekânın Tarihsel Gelişimi	19
2.2.1. Kural Tabanlı Sistemler.....	19
2.2.2. Erken Dönem Makine Öğrenmesi Modelleri	20
2.2.3. Derin Öğrenme Dönemi	21
2.2.4. Güncel Klinik Entegrasyon Eğilimleri	22
2.3. Yapay Zekâ Çalışmalarında Temel İstatistik Kavramları	23
2.3.1. Sınıflandırma Modellerinde Performans Ölçütleri	23
2.3.2. Regresyon Modellerinde Performans Ölçütleri.....	25
2.3.3. Cross-Validation Yöntemleri	26
2.3.4. Overfitting ve Underfitting.....	26
2.3.5. Bias ve Varyans Dengesi.....	27
2.3.6. Veri Seti Dengesizliği ve Etik Sonuçları.....	28
2.4. Yapay Zekânın Temel Teknik Altyapısı	29
2.4.1. Makine Öğrenmesi (Machine Learning, ML)	29
2.4.2. Derin Öğrenme (Deep Learning, DL)	30
2.4.3. Konvolüsyonel Sinir Ağları (Convolutional Neural Networks, CNN)	31
2.4.4. Transfer Learning	32

2.4.5. Açıklanabilir Yapay Zekâ (Explainable Artificial Intelligence, XAI)	32
2.4.6. Yapay Zekâ Yazılımlarının Çalışma Prensipleri	33
2.5. Ortodontik Görüntülemelerde Yapay Zekâ Uygulamaları	33
2.5.1. İki Boyutlu Radyografilerde Yapay Zekâ	34
2.5.2. Üç Boyutlu Görüntülemelerde Yapay Zekâ	36
2.5.3. Fotoğraf Tabanlı Görüntü Analizi	38
2.5.4. Görüntü İşlemede Klinik Katkıları	38
2.5.5. Görüntüleme Tabanlı Sınırlamalar	39
2.6. Dijital Dental Modellerde Yapay Zekâ	40
2.6.1. Otomatik Diş Etiketleme	41
2.6.2. Diş Segmentasyonu	42
2.6.3. Crowding Analizi	42
2.6.4. Ark Formu Analizi	43
2.6.5. Tedavi Öncesi–Sonrası Model Karşılaştırmaları.....	44
2.6.6. İntraoral Tarayıcı Verilerinin Analizi.....	44
2.7. Tedavi Planlamasında Yapay Zekâ	45
2.7.1. Maloklüzyon Sınıflandırması	46
2.7.2. Ekstraksiyon Kararlarının Desteklenmesi	46
2.7.3. Tedavi Zorluk Derecesinin Tahmini	47
2.7.4. Aparey Seçiminde Yapay Zekâ	47
2.7.5. Kişiselleştirilmiş Tedavi Önerileri	48
2.7.6. Klinik Karar Sürecine Entegrasyon.....	48
2.8. Clear Aligner Sistemleri ve Yapay Zekâ.....	49
2.8.1. Aligner Planlamasında Yapay Zekâ Kullanımı	50
2.8.2. Diş Hareketlerinin Öngörülmesi.....	50
2.8.3. Refinement İhtiyacının Tahmini.....	51
2.8.4. Set-up Optimizasyonu	51
2.8.5. Aligner Tedavilerinde Klinik Sınırlar	52

2.9. Tedavi Süresi ve Sonuç Tahmini.....	52
2.9.1. Tedavi Süresi Tahmin Modelleri.....	53
2.9.2. Tedavi Sonucu Öngörü Algoritmaları	53
2.9.3. Hasta Beklentilerinin Yönetimi.....	54
2.9.4. Tahmin Sistemlerinin Klinik Değeri	55
2.9.5. Süre Tahmininde Sınırlayıcı Faktörler	55
2.10. Ortodontik Biyomekanik, FEA ve Yapay Zekâ	56
2.10.1. Sonlu Elemanlar Analizinin (FEA) Ortodontideki Yeri.....	56
2.10.2. Yapay Zekâ ve FEA Entegrasyonu	57
2.10.3. Kişiselleştirilmiş Biyomekanik Modeller.....	58
2.10.4. Kuvvet Dağılımının Hızlı Tahmini	58
2.10.5. Deneysel ve Klinik Sınırlamalar	59
2.11. Tele-Ortodonti İş Akışlarında Yapay Zekâ	59
2.11.1. Uzaktan Hasta Takibi	60
2.11.2. Akıllı Telefon Tabanlı Yapay Zekâ Sistemleri	61
2.11.3. Otomatik Uyarı Mekanizmaları.....	61
2.11.4. Klinik Verimlilik Katkıları	62
2.11.5. Uzaktan Takibin Sınırları	62
2.12. Ortodontide Yapay Zekânın Etik ve Hukuki Boyutları.....	63
2.12.1. Yapay Zekâ Etiği.....	64
2.12.2. Automation Bias.....	64
2.12.3. Tıbbi Cihaz Regülasyonları.....	65
2.12.4. Sorumluluk Paylaşımı	65
2.12.5. Trustworthy AI İlkeleri	66
2.13. Veri Gizliliği ve Yasal Düzenlemeler	67
2.13.1. KVKK ve Kişisel Sağlık Verileri	67
2.13.2. Anonimleştirme Stratejileri	68
2.13.3. Veri Saklama Güvenliği	68
2.13.4. Uluslararası Veri Koruma Çerçeveleri	69

2.13.5. Klinik Yazılım Onay Süreçleri.....	70
2.14. Model Validasyonu ve Klinik Güvenilirlik.....	70
2.14.1. İç Validasyon.....	71
2.14.2. Dış Validasyon	71
2.14.3. Veri Kaynağına Bağlı Performans.....	72
2.14.4. Genellenebilirlik Problemleri	73
2.14.5. Klinik Kabul Kriterleri	73
2.15. AI + VR Simülasyonları.....	74
2.15.1. Ortodontik Tedavi Simülasyonlarında VR'nin Rolü.....	75
2.15.2. AI Destekli Biyomekanik Simülasyonlar	75
2.15.3. Hasta-Özgü Dijital İkiz (Digital Twin) Yaklaşımı	76
2.15.4. Klinik Karar Destek ve Hasta İletişimi	76
2.15.5. Mevcut Sınırlamalar ve Gelecek Perspektifi.....	77
2.16. AI Destekli Eğitim Yazılımları	77
2.16.1 Kişiselleştirilmiş Öğrenme ve Adaptif Eğitim	78
2.16.2. Klinik Senaryo ve Vaka Tabanlı Eğitim	79
2.16.3. Otomatik Değerlendirme ve Geri Bildirim Sistemleri	79
2.16.4. Standartlaştırılmış Eğitim ve Yetkinlik Ölçümü	80
2.16.5. Etik ve Eğitsel Sınırlamalar.....	80
SONUÇ VE GELECEK PERSPEKTİFLERİ.....	81
KAYNAKÇA	84

ÖNSÖZ

Ortodonti bilimi, son yirmi yılda dijital teknolojilerin hızlı entegrasyonu ile köklü ve geri döndürülemez bir dönüşüm sürecine girmiştir. Dijital radyografi, konik ışınlı bilgisayarlı tomografi gibi ileri görüntüleme yöntemleri, üç boyutlu yüz ve dental ark analizleri, bilgisayar destekli tedavi planlama yazılımları ve intraoral tarayıcılar, günümüz klinik pratiğinin vazgeçilmez bileşenleri hâline gelmiştir. Bu dijital ekosistem, ortodontik tanı ve tedavi süreçlerini daha görsel, daha ölçülebilir ve daha hasta odaklı bir yapıya taşımıştır. Bu dönüşümün en yeni, en dinamik ve en etkili bileşeni ise yapay zekâ uygulamalarıdır.

Yapay zekâ, yalnızca bilgisayarların hesaplama gücündeki artışla değil; aynı zamanda büyük veri kümelerine erişimin kolaylaşması, bulut tabanlı depolama sistemlerinin yaygınlaşması ve gelişmiş öğrenme algoritmalarının klinik problemlere başarıyla uyarlanabilmesi sayesinde ortodontide yeni bir paradigma oluşturmuştur. Daha önce saatler süren manuel analizlerin dakikalar hatta saniyeler içinde gerçekleştirilebilmesi, karmaşık verilerin bütüncül biçimde değerlendirilebilmesi ve klinik karar destek mekanizmalarının geliştirilebilmesi, bu paradigmanın temelini meydana getirmektedir.

Geleneksel ortodontik değerlendirme süreçleri, büyük ölçüde klinisyenin bireysel deneyimine, manuel ölçümlere ve belirli ölçüde subjektif yorumlara dayanır. Klinik tecrübe ortodontinin ruhunda her zaman merkezi bir konumda olacak olsa da, yapay zekâ tabanlı

sistemler bu süreci daha standart, daha objektif, tekrarlanabilir ve zaman açısından verimli hâle getirmeyi amaçlamaktadır. Özellikle otomatik sefalometrik analizler, dijital model ve oklüzyon değerlendirmeleri, tedavi planlamasında alternatif senaryoların oluşturulması, tedavi süresi ve zorluk derecesinin tahmini gibi alanlarda yapay zekâ uygulamaları dikkat çekici bir gelişim göstermekte; bilimsel araştırmalar ve ticari yazılımlar aracılığıyla her geçen gün daha geniş bir kullanım alanı bulmaktadır.

Elinizdeki bu kitabın temel amacı, ortodontide yapay zekâ kavramını ve uygulamalarını yalnızca teknik ve algoritmik yönleriyle değil; aynı zamanda klinik yansımaları, etik sorumlulukları, hukuki çerçevesi ve gelecek perspektifleriyle kapsamlı biçimde ele almaktır. Yapay zekâ alanı, disiplinler arası bir bilgi birikimi gerektirmektedir. Bu nedenle kitap; mühendislik temelli kavramları ortodonti pratiğiyle buluşturan, karma okuyucu kitlesinin de rahatlıkla anlayabileceği bir dil ve kurguyla tasarlanmıştır.

Kitap içeriği; ortodonti asistanları, klinik ortodontistler, diş hekimliği öğrencileri ve akademisyenler için yol gösterici bir başvuru kaynağı olacak şekilde yapılandırılmıştır. Teorik altyapının yanı sıra, güncel bilimsel literatüre dayanan klinik uygulama örnekleri, adım adım kullanım rehberleri, karşılaştırmalı değerlendirmeler ve kanıta dayalı öneriler sunulmaktadır. Amacımız, okuyucunun yapay zekâ teknolojilerini eleştirel bir bakış açısıyla tanımasını sağlamak, hangi aşamada nasıl kullanılabileceği konusunda farkındalık kazandırmak ve bu sistemlerin güçlü ile sınırlı yönlerini objektif biçimde ortaya koymaktır.

Özellikle vurgulamak isterim ki yapay zekânın ortodontideki rolü, hiçbir zaman klinisyenin yerini almak değildir. Aksine yapay zekâ; klinisyeni destekleyen, karar verme sürecini güçlendiren, hata payını azaltan ve hasta bakım kalitesini iyileştiren güçlü bir yardımcı araç olarak görülmelidir. Ortodontik tedavinin merkezinde hasta, karar verici konumda ise her zaman hekim olacaktır. Bu kitap, okuyucuya tam da bu dengeli ve gerçekçi bakış açısını kazandırmayı hedeflemektedir.

Ortodontide yapay zekâ konusunda Türkçe literatürdeki bilgi ihtiyacını karşılamaya yönelik hazırlanan bu eserin, siz değerli meslektaşlarımıza ve tüm ilgililere yararlı olmasını diliyorum. Dijital ortodontinin geleceğine ışık tutacak yeni fikirlerin ve bilimsel çalışmaların, bu kitap aracılığıyla daha da güçleneceğine inanıyorum.

KISALTMALAR LİSTESİ

AI	: Artificial Intelligence (Yapay Zekâ)
AUC	: Area Under the Curve (Eğri Altı Alan)
CBCT	: Cone-Beam Computed Tomography (Konik Işınlı Bilgisayarlı Tomografi)
CE	: Conformité Européenne (Avrupa Uygunluk İşareti)
CNN	: Convolutional Neural Network (Evrişimli Sinir Ağı)
DL	: Deep Learning (Derin Öğrenme)
EU	: European Union (Avrupa Birliği)
CE	: Conformité Européenne (Avrupa Uygunluk İşareti)
FEA	: Finite Element Analysis (Sonlu Elemanlar Analizi)
FDA	: Food and Drug Administration (ABD Gıda ve İlaç Dairesi)
GDPR	: General Data Protection Regulation (Genel Veri Koruma Tüzüğü)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
ML	: Machine Learning (Makine Öğrenmesi)
MSE	: Mean Squared Error (Ortalama Kare Hata)
RMSE	: Root Mean Squared Error (Karekök Ortalama Kare Hata)
ROC	: Receiver Operating Characteristic (Alıcı İşlem Karakteristiği)
VR	: Virtual Reality (Sanal Gerçeklik)
XAI	: Explainable Artificial Intelligence (Açıklanabilir Yapay Zekâ)

YAPAY ZEKÂ TERİMLERİ SÖZLÜĞÜ

Yapay Zekâ (*Artificial Intelligence*): İnsan zekâsını taklit edebilen; öğrenme, akıl yürütme, örüntü tanıma ve karar verme gibi yeteneklere sahip bilgisayar sistemlerini tanımlayan genel kavram.

Makine Öğrenmesi (*Machine Learning*): Bilgisayar sistemlerinin açıkça programlanmadan, verilerden öğrenmesini sağlayan yapay zekâ alt dalı.

Derin Öğrenme (*Deep Learning*): Çok katmanlı yapay sinir ağlarına dayanan, özellikle görüntü ve ses verilerinde yüksek başarı sağlayan makine öğrenmesi yaklaşımı.

Evrişimli Sinir Ağı (*Convolutional Neural Network-CNN*): Görüntü verilerinin analizinde kullanılan özel bir derin öğrenme mimarisi.

Açıklanabilir Yapay Zekâ (*Explainable Artificial Intelligence-XAI*): Yapay zekâ modellerinin karar verme süreçlerinin klinisyen tarafından anlaşılabilir hâle getirilmesini amaçlayan yöntemler bütünü.

Eğitim Veri Seti (*Training Dataset*): Yapay zekâ modelinin öğrenme sürecinde kullanılan, etiketlenmiş veya etiketlenmemiş veri kümesi.

Doğrulama Veri Seti (*Validation Dataset*): Modelin aşırı öğrenmesini önlemek ve performansını izlemek amacıyla eğitim sırasında kullanılan veri kümesi.

Test Veri Seti (*Test Dataset*): Modelin gerçek performansını değerlendirmek için eğitim sürecine dâhil edilmemiş veri kümesi.

Doğruluk (*Accuracy*): Modelin doğru tahminlerinin toplam tahmin sayısına oranını ifade eden performans ölçütü.

Hassasiyet (*Sensitivity*): Gerçek pozitif vakaların doğru biçimde tanımlanma oranını ifade eder.

Özgüllük (*Specificity*): Gerçek negatif vakaların doğru biçimde tanımlanma oranını gösterir.

ROC Eğrisi (*Receiver Operating Characteristic Curve*): Bir sınıflandırma modelinin farklı eşik değerlerindeki performansını gösteren grafiksel yöntem.

Aşırı Öğrenme (*Overfitting*): Modelin eğitim verisine aşırı uyum sağlayarak yeni verilerde düşük performans göstermesi durumu.

Yetersiz Öğrenme (*Underfitting*): Modelin veri yapısını yeterince öğrenememesi nedeniyle düşük performans göstermesi.

Önyargı (*Bias*): Veri setindeki dengesizlikler veya model yapısından kaynaklanan sistematik hataları ifade eder.

Varyans (*Variance*): Modelin veri değişikliklerine karşı aşırı duyarlı olma derecesi.

Çapraz Doğrulama (*Cross-Validation*): Veri setinin farklı alt kümelere bölünerek model performansının tekrarlı biçimde değerlendirilmesini sağlayan istatistiksel yöntem.

Dijital İkiz (*Digital Twin*): Hastaya özgü anatomik ve biyolojik verilerle oluşturulan, tedavi senaryolarının simülasyonuna olanak tanıyan sanal modeller.

Klinik Karar Destek Sistemi (*Clinical Decision Support System*): Klinisyenin karar verme sürecini destekleyen, nihai kararı otomatik olarak vermeyen yapay zekâ tabanlı sistemler.

1. GİRİŞ

Yapay zekâ (*Artificial Intelligence*, AI), insan zekâsına özgü öğrenme, akıl yürütme, problem çözme ve karar verme gibi bilişsel süreçleri taklit edebilen bilgisayar sistemlerini tanımlayan disiplinler arası bir kavramdır. Yapay zekâ terimi, tek bir teknolojiyi değil; veri bilimi, istatistik, bilgisayar mühendisliği ve bilişsel bilimler gibi alanların kesişiminde yer alan çok sayıda yöntem ve yaklaşımı kapsar. AI kavramının felsefi temelleri 1950’li yıllarda Alan Turing’in makinelerin düşünebilme kapasitesini sorgulayan çalışmalarıyla şekillenmiş, ilerleyen yıllarda ise kural tabanlı uzman sistemler aracılığıyla pratik uygulama alanları bulmaya başlamıştır. AI’nın modern bilimsel çerçevesi ve algoritmik altyapısı, örüntü tanıma ve olasılıksal modelleme prensipleri üzerine kurulmuştur (Bishop, 2019; Goodfellow ve ark., 2016).

Son on yılda AI, özellikle sağlık bilimlerinde belirgin bir ivme kazanmıştır. Bu ivmenin arkasında artan hesaplama kapasitesi, büyük ölçekli dijital veri kümelerinin oluşması ve derin öğrenme tabanlı gelişmiş algoritmaların klinik problemlere başarıyla uygulanabilmesi yer almaktadır. Büyük veri analitiği ve makine öğrenmesi teknikleri, karmaşık medikal verilerin insan müdahalesine gerek kalmadan analiz edilmesini mümkün hâle getirmiştir (Litjens ve ark., 2017). Özellikle konvolüsyonel sinir ağları (CNN) ve derin yapay sinir ağı mimarileri, görüntü temelli tanısal görevlerde AI’nın temel itici gücü olmuştur (He ve ark., 2016).

Tıp alanında AI uygulamaları, radyoloji ve patoloji gibi görüntü yoğun disiplinlerde erken dönemde gelişmiştir. Derin öğrenme tabanlı modellerin akciğer hastalıkları, deri lezyonları ve histopatolojik görüntülerin sınıflandırılması gibi alanlarda insan uzmanlarla benzer performans gösterebildiği bildirilmiştir (Topol, 2019). Bu erken başarılar, diş hekimliğinde de benzer sistemlerin geliştirilebileceği fikrini güçlendirmiştir. Diş hekimliği uygulamalarında AI'ın potansiyelini ve sınırlamalarını ele alan güncel çalışmalar, AI'nın özellikle tanısal süreçlerde önemli fırsatlar sunduğunu vurgulamaktadır (Schwendicke ve ark., 2020; Gokdeniz & Kamburoğlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023).

Ortodonti, yapısı gereği çok sayıda farklı veri kaynağının bütüncül biçimde değerlendirilmesini gerektiren karmaşık bir klinik disiplindir. Ortodontik tanı ve tedavi planlamasında kullanılan temel veri türleri:

- lateral sefalometrik radyografiler,
- panoramik radyografiler,
- konik ışınlı bilgisayarlı tomografi (CBCT) görüntüleri,
- dijital dental modeller,
- yüz fotoğrafları ve
- klinik muayene bulguları

şeklinde özetlenebilir.

Geleneksel ortodontik iş akışında bu verilerin analizi büyük ölçüde manuel yöntemlerle gerçekleştirilmekte; landmark noktalarının işaretlenmesi, açısal ve lineer ölçümlerinin yapılması ve tedavi

seeneklerinin belirlenmesi klinisyen aısından nemli lde zaman almaktadır. Ayrıca bu sre, operatrler arası farklılıklara ve belirli lde subjektif yorumlara aıktır (Liu ve ark., 2023a; 2023b). Klinik deneyim ortodontide her zaman temel belirleyici unsur olmaya devam edecek olsa da manuel lmlerin doėası gereėi hata payı kaçınılmazdır (Cabitza ve ark., 2017; Topol, 2019).

AI tabanlı sistemler, ortodontide tanı srelerinin otomatikleştirilmesi ve standardizasyonu aısından nemli avantajlar sunmaktadır. Derin ėrenme algoritmaları sayesinde grntler zerinde otomatik landmark tespiti yapılabilmekte, dijital modeller segmentlere ayrılabilmekte ve tedavi sresine ynelik ok deėiřkenli tahminler retilenmektedir (Liu ve ark., 2023b; Wong ve ark., 2023; Gracea ve ark., 2025). Bu geliřmeler, AI’nın ortodontide bir “karar destek aracı” olarak kullanımını giderek daha gereki hle getirmiřtir (American Dental Association, 2023).

zellikle clear aligner sistemlerinin tamamen dijital planlama temelli yapısı, AI algoritmalarının kiřiselleřtirilmiř tedavi yaklařımlarına uygulanabilmesi iin ideal bir zemin oluřturmuřtur (Liu ve ark., 2023b; Tomášik ve ark., 2024). Bununla birlikte AI’nın klinik ortama entegrasyonu hlen geliřmekte olan dinamik bir sretir. Birok model arařtırma ařamasında bulunmakta; etik sorumluluklar, veri gizliliėi ve yasal dzenlemeler ise bu teknolojilerin yaygın kabulnde belirleyici rol oynamaktadır (European Commission, 2019).

Elinizdeki bu kitabın ana motivasyonu, ortodontide AI uygulamalarını bilimsel temelleriyle tanıtmak, mevcut klinik

yansımalarını objektif biçimde değerlendirmek ve gelecek yıllarda bu disiplinin hangi alanlara doğru evrilebileceği konusunda okuyucuya kapsamlı bir perspektif sunmaktır. AI teknolojileri, doğru konumlandırıldığında klinisyenin karar verme kapasitesini güçlendiren ve hasta bakım kalitesini artıran etkili araçlar olarak ortodontinin geleceğinde merkezi bir yer edinecektir.

2. GENEL BİLGİLER

2.1. Yapay Zekânın Ortodontiye Girişi ve Dijital Dönüşüm

2.1.1. Dijital Ortodontinin Evrimi

Ortodonti pratiğinde dijital dönüşüm, 2000’li yılların başından itibaren tanı kayıtlarının bilgisayar ortamına aktarılmasıyla başlamış ve kısa sürede klinik uygulamaların hemen her aşamasına yayılmıştır. Geleneksel olarak asetat kâğıtları üzerinde manuel olarak gerçekleştirilen sefalometrik ölçümler, dijital radyografi yazılımlarının kullanıma girmesiyle birlikte daha objektif ve ölçülebilir bir yapıya kavuşmuştur (Bishop, 2019). Üç boyutlu görüntüleme teknolojilerinin gelişmesi, yüz iskeletinin ve dentofasiyal yapıların volumetrik olarak analiz edilmesine olanak tanımış; bu durum ortodontik tanı süreçlerinin kapsamını genişletmiştir (Gokdeniz & Kamburoğlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023).

İntraoral tarayıcıların yaygınlaşması, dijital ortodontinin evrimindeki en önemli kilometre taşlarından birini oluşturmuştur. Alçı model elde edilmesine dayalı geleneksel yöntemler; yerlerini STL formatında saklanabilen, sanal ortamda ölçülebilen ve farklı yazılımlar arasında paylaşılabilen dijital modellere bırakmıştır (Graber, 2016). Bu modeller, yalnızca ark uzunluğu ve Bolton analizi gibi temel değerlendirmelerde değil; oklüzyon simülasyonu, tedavi set-up’larının hazırlanması ve kişiselleştirilmiş aparey üretimi gibi ileri uygulamalarda da kullanılmaya başlanmıştır (Liu ve ark., 2023b; Tomášik ve ark., 2024).

Bilgisayar destekli tasarım ve üretim (CAD/CAM) teknolojilerinin ortodontiye entegrasyonu sayesinde, kişiye özel braket tabanları, indirekt bonding plakları ve clear aligner aparatları tamamen dijital platformlar üzerinden planlanabilir hâle gelmiştir (Liu ve ark., 2023b; Wong ve ark., 2023). Randomize kontrollü çalışmalar ve klinik raporlar, dijital iş akışlarının tedavi planlamasında zaman kazancı sağladığını ve ölçüm güvenilirliğini artırdığını ortaya koymuştur (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

Dijital ortodontinin bu hızlı ilerleyişi, AI uygulamalarının klinik ortama girişine zemin hazırlayan temel faktör olmuştur. Görüntüleme ve model verilerinin standardize formatlarda saklanması, otomatik analiz algoritmalarının geliştirilmesine olanak tanımış; böylece AI teknolojileri ortodontide doğal bir entegrasyon alanı bulmuştur (American Dental Association, 2023).

Dijitalleşmenin klinik pratiğe yansması, AI sistemlerinin kullanılabilirliğini doğrudan etkilemektedir. Günümüzde birçok ticari yazılım, otomatik sefalometri analizi ve dijital model ölçümü gibi görevleri saniyeler içinde gerçekleştirebilmekte; bu durum klinik randevu sürelerinin kısalmasına ve hasta bilgilendirme süreçlerinin hızlanmasına katkı sağlamaktadır (Gracea ve ark., 2025). Bununla birlikte dijital sistemlerin çıktıları, her zaman klinisyen kontrolüyle birlikte değerlendirilmelidir (Cabitza ve ark., 2017; Topol, 2019).

2.1.2. Yapay Zekânın Ortodontik Veriye Uygunluğu

Ortodonti, teşhis ve tedavi planlamasında yoğun biçimde yapılandırılmış sayısal veri ve görüntü kullanan nadir sağlık disiplinlerinden biridir. Bu özellik, AI'nın uygulanması açısından önemli bir avantaj sunmaktadır. Lateral sefalogramlar, panoramik radyografiler ve CBCT görüntüleri gibi standart ortodontik kayıtlar, derin öğrenme algoritmaları için ideal girdi türleridir (Liu ve ark., 2023a; 2023b).

Makine öğrenmesi yöntemleri, ortodontik maloklüzyon tiplerinin sınıflandırılması, tedavi zorluk derecesinin öngörülmesi ve tedavi süresinin tahmini gibi çok değişkenli analiz gerektiren görevlerde başarıyla kullanılabilir (Liu ve ark., 2023b; Wong ve ark., 2023). Dijital dental modeller üzerinde yapılan ölçümler ise hem regresyon hem de segmentasyon temelli derin öğrenme yaklaşımları için elverişlidir (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

Özellikle derin öğrenme algoritmalarının en güçlü yönü, görüntülerden otomatik olarak anlamlı özellikleri çıkarabilmesidir. Bu nedenle geleneksel istatistiksel ölçüm gerektiren birçok ortodontik değerlendirme, AI sistemleri tarafından daha hızlı ve daha standart biçimde gerçekleştirilebilir hâle gelmiştir (Gokdeniz & Kamburoğlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023; Park J. ve ark., 2019).

AI'nın ortodontik veriye uygunluğu, klinikte otomatik teşhis sistemlerinin yaygınlaşmasına imkân tanımıştır. Örneğin gömülü kaninlerin otomatik tespiti, diş numaralandırma ve ark formu

analizleri gibi görevler, AI algoritmalarının günlük pratiğe en somut katkılarıdır (Mason ve ark., 2023; Köktürk ve ark., 2024). Ancak modellerin heterojen popülasyonlarda test edilmesi ve klinik geçerliliklerinin kanıtlanması zorunludur (Cabitza ve ark., 2017; Topol, 2019).

2.1.3. AI Tabanlı Karar Destek Sistemleri Kavramı

Ortodontide AI'nın klinik kullanıma yönelik en önemli yansıması, karar destek sistemleri (AI-based Decision Support Systems) şeklinde karşımıza çıkmaktadır. Bu sistemlerin temel amacı, hekimin yerine geçmek değil; aksine klinisyenin teşhis ve planlama süreçlerini daha güçlü veri analitiği araçlarıyla desteklemektir (American Dental Association, 2023).

AI tabanlı karar destek sistemleri, geçmiş vaka verilerinden öğrenerek yeni hastalar için:

- maloklüzyon tipi,
- ekstraksiyon gerekliliği,
- tedavi süresi,
- tedavi sonucu öngörüsü

gibi alanlarda tahminler sunabilmektedir (Gracea ve ark., 2025).

Bu sistemlerin klinik kabulünde açıklanabilirlik (explainability) kavramı giderek daha önemli hâle gelmektedir. XAI yaklaşımları sayesinde, modelin hangi parametrelere dayanarak karar verdiği klinisyene sunulmakta; böylece sistem önerileri daha şeffaf biçimde yorumlanabilmektedir (European Commission, 2019).

AI destekli ortodontik sistemlerin kullanımında otomasyon yanlışlığı riskine dikkat çekilmiş ve otomatik çıktılara aşırı güvenmenin klinik hatalara yol açabileceği belirtilmiştir (Cabitza ve ark., 2017; Topol, 2019). Bu nedenle tüm AI tabanlı karar sistemlerinde son karar merciinin mutlaka hekim olması gerektiği vurgulanmaktadır (Liu ve ark., 2023a; 2023b).

Doğru konumlandırılmış AI karar destek sistemleri, klinikte tedavi planlama sürelerini kısaltmakta, özellikle genç ve deneyimi sınırlı klinisyenler için yol gösterici rehberler sunmakta ve ölçüm standardizasyonunu artırmaktadır (Liu ve ark., 2023b; Wong ve ark., 2023). Bununla birlikte etik sorumlulukların ve hasta güvenliğinin korunması açısından, sistemlerin yalnızca yardımcı araç olarak kullanılması zorunludur (American Dental Association, 2023).

2.2. Ortodontide Yapay Zekânın Tarihsel Gelişimi

AI'nın ortodontiye entegrasyonu, genel tıp alanındaki gelişmelerle paralel biçimde ilerlemiş; ancak disipline özgü ihtiyaçlar nedeniyle kendine has bir evrimsel yol izlemiştir. İlk yıllarda daha çok bilgisayar destekli ölçüm yazılımları ve istatistiksel karar algoritmaları ön plandayken, günümüzde derin öğrenme tabanlı otomatik tanı sistemleri yaygınlaşmaya başlamıştır. Bu tarihsel süreç, ortodontide AI'nın gelişimini anlamada önemli bir perspektif sunmaktadır (Bishop, 2019; Schwendicke ve ark., 2020).

2.2.1. Kural Tabanlı Sistemler

Ortodontide AI'ya yönelik en erken uygulamalar, 1990'lı ve 2000'li yıllarda geliştirilen kural tabanlı uzman sistemlere

dayanmaktadır. Bu sistemlerde, deneyimli ortodontistlerin teşhis ve tedavi planlama mantıkları algoritmik kurallar şeklinde modellenmeye çalışılmıştır. Sefalometrik normlar, Angle sınıflaması, yer darlığı miktarı ve büyüme-gelişim değerlendirmeleri gibi parametreler “if-then” mantığında programlanmış yazılımlar aracılığıyla yorumlanmıştır (Thanathornwong, 2018).

Bu yaklaşımlar, klinisyenlere teorik rehberlik sunmuş olsa da, gerçek hasta çeşitliliğini yansıtmakta zorlanmışlardır. Kuralların statik olması, ara değerlerin ve istisnai durumların sisteme dâhil edilememesi gibi nedenlerle performansları sınırlı kalmıştır. Bununla birlikte bu dönem, ortodontik karar verme süreçlerinin dijital ortamda yapılandırılabileceğini göstermesi açısından önemlidir (Graber, 2016).

2.2.2. Erken Dönem Makine Öğrenmesi Modelleri

Makine öğrenmesi algoritmalarının yaygınlaşmasıyla birlikte ortodontide AI çalışmaları yeni bir boyut kazanmıştır. 2000’li yılların sonu ve 2010’lu yılların başlarında, manuel olarak elde edilen ölçüm verilerinin decision tree ve destek vektör makineleri gibi algoritmalarla analiz edildiği çalışmalar yayımlanmaya başlamıştır (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

Bu dönemdeki araştırmalar özellikle iskeletsel maloklüzyon sınıflandırması, gömülü dişlerin tespiti, büyüme yönünün tahmini, tedavi süresinin öngörülmesi gibi alanlara odaklanmıştır (Liu ve ark., 2023b; Wong ve ark., 2023).

Ancak bu modeller, çoğunlukla küçük ölçekli ve tek merkezli veri setleriyle geliştirildiğinden, genellenebilirlik açısından yeterli

düzeye ulaşamamıştır. Yine de makine öğrenmesinin çok değişkenli analiz kapasitesi, AI'nın ortodontide kullanılabilirliğine ilişkin umut verici ilk sonuçların elde edilmesini sağlamıştır (Cabitza ve ark., 2017; Topol, 2019).

2.2.3. Derin Öğrenme Dönemi

Ortodontide AI'nın gerçek anlamda klinik potansiyel göstermesi, derin öğrenme algoritmalarının gelişmesiyle mümkün olmuştur. Özellikle konvolüsyonel sinir ağlarının görüntü temelli görevlerde üstün performans sergilemesi, ortodontik radyografilerin otomatik analizine yönelik araştırmaların hızla artmasına neden olmuştur (He ve ark., 2016; Ronneberger ve ark., 2015).

Park J. ve ark. (2019), CNN tabanlı otomatik landmark tespit sistemlerinin manuel sefalometrik analizlere oldukça yakın sonuçlar üretebildiğini göstermiştir. Bu çalışma, ortodonti literatüründe derin öğrenme tabanlı sefalometri analizlerinin başlangıcı olarak kabul edilmektedir (Park J. ve ark., 2019).

Takip eden yıllarda yapılan araştırmalar, U-Net, ResNet, YOLO ve benzeri modern mimarilerin lateral sefalogramlarda otomatik nokta tespiti, panoramik radyografilerde diş segmentasyonu, CBCT görüntülerinde otomatik yapı tanımlama gibi alanlarda başarıyla kullanılabileceğini ortaya koymuştur (Gracea ve ark., 2025; Mason ve ark., 2023; Köktürk ve ark., 2024; Jeong ve ark., 2021; Nan ve ark., 2023). 2020 sonrası dönemde IEEE ve Avrupa Komisyonu gibi kuruluşlar tarafından yayımlanan güvenilir AI rehberleri, bu teknolojilerin klinik uygulamaya aktarılmasında etik çerçevenin

önemini daha görünür kılmıştır (European Commission, 2019; IEEE Global Initiative, 2020).

2.2.4. Güncel Klinik Entegrasyon Eğilimleri

Günümüzde ortodontide AI çalışmaları, yalnızca araştırma laboratuvarlarıyla sınırlı kalmayıp ticari yazılımlar ve klinik platformlar aracılığıyla günlük pratiğe entegre edilmeye başlanmıştır. Otomatik sefalometri analiz programları, AI destekli gömülü kanin tespit sistemleri ve dijital model analiz araçları birçok klinikte rutin kullanım alanı bulmaktadır (American Dental Association, 2023).

Ayrıca 3B görüntülerde AI kullanımı, son yıllarda önemli bir araştırma odağı hâline gelmiştir. Gao ve ark. (2025), multimodal derin öğrenme yaklaşımlarının 3B ortodontik görüntülerde daha başarılı tanı ve tahminler üretebildiğini bildirmiştir (Gao ve ark., 2025). Tele-ortodonti uygulamalarının yaygınlaşmasıyla birlikte, uzaktan takip sistemlerinde otomatik değerlendirme ve erken uyarı mekanizmaları da klinik iş akışının önemli bileşenleri arasına girmeye başlamıştır (Lo Giudice ve ark., 2022; Sangalli ve ark., 2024).

European Orthodontic Society (2024) tarafından yayımlanan konum raporu, AI uygulamalarının ortodonti alanında hızla geliştiğini; ancak klinik kullanım için daha kapsamlı dış validasyon çalışmalarına ihtiyaç olduğunu vurgulamıştır. Bu rapor, AI'nın ortodontideki güncel konumunu destekleyen en önemli uluslararası belgelerden biri olarak görülmektedir (European Orthodontic Society, 2024).

2.3. Yapay Zekâ Çalışmalarında Temel İstatistik

Kavramları

Ortodontide AI tabanlı sistemlerin klinik kullanıma aktarılabilmesi, yalnızca algoritmik doğrulukla değil; bu algoritmaların istatistiksel olarak doğru biçimde değerlendirilmesiyle mümkündür. Yanlış veya eksik istatistiksel yorumlar, bir modelin gerçek klinik performansının olduğundan daha iyi ya da daha kötü algılanmasına yol açabilir. Bu nedenle AI çalışmalarında kullanılan temel istatistik kavramlarının anlaşılması, klinisyenler ve araştırmacılar açısından kritik öneme sahiptir (Litjens ve ark., 2017; Bishop, 2019).

Ortodonti literatüründe AI uygulamalarının büyük bir bölümü, sınıflandırma veya regresyon temelli modellerden oluşmaktadır. Bu modellerin her biri, farklı performans ölçütleri ve validasyon yaklaşımları gerektirir (Hastie ve ark., 2009). Aşağıda, ortodontik AI çalışmalarında en sık kullanılan istatistik kavramlar sistematik biçimde ele alınmaktadır.

2.3.1. Sınıflandırma Modellerinde Performans Ölçütleri

Sınıflandırma modelleri, bir girdiyi önceden tanımlanmış kategorilerden birine atamayı amaçlayan AI sistemleridir. Ortodontide iskeletsel sınıf tayini, gömülü diş varlığının tespiti veya tedavi gerekliliğinin öngörülmesi gibi görevler bu gruba girer (Liu ve ark., 2023a; 2023b).

Bu modellerin performansı, genellikle aşağıdaki temel ölçütler kullanılarak değerlendirilir (Powers, 2020):

Doğruluk (Accuracy): Modelin tüm tahminleri içerisindeki doğru tahmin oranı,

Hassasiyet (Sensitivity/Recall): Gerçek pozitif vakaların ne kadarının doğru tanımlandığı,

Özgüllük (Specificity): Gerçek negatif vakaların doğru biçimde dışlanma oranı,

Kesinlik (Precision): Pozitif tahminlerin ne kadarının gerçekten pozitif olduğu,

F1 skoru: Hassasiyet ve kesinliğin harmonik ortalaması.

Ortodontik tanı sistemlerinde tek başına doğruluk değeri çoğu zaman yanıltıcı olabilir. Özellikle sınıf dağılımının dengesiz olduğu veri setlerinde, yüksek doğruluk değeri klinik olarak düşük anlam taşıyabilir. Örneğin nadir görülen bir anomalinin tespitinde, modelin hassasiyetinin düşük olması klinik açıdan kabul edilemez sonuçlara yol açabilir (Cabitza ve ark., 2017; Topol, 2019).

Bu nedenle sınıflandırma modellerinin değerlendirilmesinde **ROC eğrisi** ve **AUC (Area Under the Curve)** gibi eşik bağımsız ölçütlerin raporlanması önerilmektedir (Litjens ve ark., 2017; Gracea ve ark., 2025; Saito & Rehmsmeier, 2015; Beam & Kohane, 2018).

Ortodontik AI çalışmalarında çoklu performans ölçütlerinin birlikte sunulması, klinik yorumlanabilirliği artırmaktadır (Koletsı ve ark., 2021).

2.3.2. Regresyon Modellerinde Performans Ölçütleri

Regresyon modelleri, kategorik sınıflar yerine sürekli nicel çıktılar üretir. Ortodontide tedavi süresi tahmini, diş hareket miktarının öngörülmesi veya ark uzunluğu değişiminin hesaplanması bu kapsama girer (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

Bu tür modellerin değerlendirilmesinde en sık kullanılan ölçütler şunlardır (Hastie ve ark., 2009):

- **Ortalama Mutlak Hata (Mean Absolute Error, MAE),**
- **Ortalama Kare Hata (Mean Squared Error, MSE),**
- **Kök Ortalama Kare Hata (Root Mean Squared Error, RMSE),**
- **Gerçek ve tahmin edilen değerler arasındaki korelasyon katsayısı.**

Tedavi süresi tahmini yapan bir makine öğrenmesi modelinin ± 3 ay civarında MAE değerine sahip olmasının, klinik beklenti yönetimi açısından anlamlı kabul edilebileceği bildirilmiştir (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025). Bununla birlikte hata değerlerinin yorumlanması, her zaman klinik bağlam göz önünde bulundurularak yapılmalıdır (Volovic ve ark., 2023; Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

Regresyon modellerinde yüksek korelasyon katsayısı, her zaman düşük hata anlamına gelmez. Bu nedenle yalnızca korelasyon değerlerinin raporlanması yeterli değildir; mutlaka hata ölçütleriyle birlikte değerlendirilmelidir (Koletsı ve ark., 2021).

2.3.3. Cross-Validation Yöntemleri

AI modellerinin performansını değerlendirirken en sık yapılan metodolojik hatalardan biri, modelin yalnızca eğitim verisi üzerinde test edilmesidir. Bu durum, modelin gerçek dünyadaki performansını yansıtmaz ve aşırı iyimser sonuçlara yol açabilir (Bishop, 2019).

Cross-validation, veri setinin birden fazla alt kümeye bölünerek modelin farklı kombinasyonlarda eğitilip test edilmesini sağlayan bir yöntemdir. Ortodonti alanında en sık kullanılan yaklaşım **k-fold cross-validation** yöntemidir. Bu yöntemde veri seti k parçaya bölünür; her bir parça sırasıyla test verisi olarak kullanılırken geri kalan parçalar eğitim verisi olarak değerlendirilir (Litjens ve ark., 2017).

Ortodontik çalışmalarda cross-validation kullanılmaması veya yetersiz raporlanması, model performansının olduğundan yüksek görünmesine yol açabilmektedir. Bu nedenle literatürde, kullanılan validasyon yöntemlerinin açık biçimde belirtilmesi önerilmektedir (Beam & Kohane, 2018).

Özellikle küçük ölçekli ve tek merkezli ortodontik veri setlerinde cross-validation kullanımı, model performansının daha güvenilir biçimde raporlanmasını sağlar (Cabitza ve ark., 2017; Topol, 2019).

2.3.4. Overfitting ve Underfitting

Derin öğrenme tabanlı ortodontik AI sistemlerinde en sık karşılaşılan problemlerden biri **overfitting**'dir. Overfitting, modelin

eğitim verisini çok iyi öğrenmesine rağmen yeni verilerde başarısız olması durumunu ifade eder. Bu durum genellikle:

- sınırlı veri setleri,
- aşırı karmaşık ağ mimarileri,
- yetersiz regularizasyon

sonucunda ortaya çıkar (Hastie ve ark., 2009; Goodfellow ve ark., 2016).

Bu risklerin azaltılması için veri artırma (data augmentation), düzenlileştirme (regularization) ve erken durdurma (early stopping) gibi yöntemlerin kullanılması önerilmektedir (Goodfellow ve ark., 2016).

Buna karşılık **underfitting**, modelin veri setindeki temel örüntüleri dahi öğrenememesi durumudur. Bu problem ise genellikle çok basit model mimarileri veya yetersiz eğitim süresiyle ilişkilidir (Bishop, 2019).

Ortodontide klinik olarak kullanılabilir AI modelleri geliştirmek için bu iki uç durum arasında optimal bir denge kurulması gerekmektedir.

2.3.5. Bias ve Varyans Dengesi

Bias–varyans dengesi, AI modellerinin genellenebilirliğini belirleyen temel kavramlardan biridir. Yüksek bias, modelin veriyi yeterince öğrenemediğini; yüksek varyans ise modelin eğitime aşırı uyum sağladığını gösterir (Goodfellow ve ark., 2016). Ortodontik uygulamalarda bu dengenin sağlanamaması, belirli hasta gruplarında

hatalı kararların sistematik hâle gelmesine neden olabilir (Beam & Kohane, 2018).

Ortodontik veri setlerinde bias oluşumunun en önemli nedenleri arasında:

- tek merkezli veri kullanımı,
- yaş ve cinsiyet dağılımındaki dengesizlikler,
- etnik çeşitliliğin yetersizliği

yer almaktadır (Cabitza ve ark., 2017; Topol, 2019).

Bu tür sistematik yanlılıklar, bazı hasta gruplarında AI modellerinin daha düşük performans göstermesine yol açabilir. Bu nedenle çok merkezli ve heterojen veri setleriyle yapılan çalışmalar, klinik entegrasyon açısından daha güvenilir kabul edilmektedir (European Orthodontic Society, 2024).

2.3.6. Veri Seti Dengesizliği ve Etik Sonuçları

Ortodontik AI çalışmalarında veri seti dengesizliği, sınıflardan birinin diğerlerine göre çok daha fazla temsil edilmesi durumunu ifade eder. Örneğin Sınıf I vakaların Sınıf III vakalara göre çok daha fazla yer aldığı bir veri setinde eğitilen model, nadir görülen durumlarda başarısız olabilir (Liu ve ark., 2023a; 2023b).

Bu durum yalnızca teknik bir problem değil, aynı zamanda **etik bir sorundur**. Yanlı veri setleriyle eğitilen modeller, belirli hasta gruplarında sistematik hatalara yol açabilir (Saito & Rehmsmeier, 2015) ve eşitsiz sağlık hizmeti riskini artırabilir (European Commission, 2019).

Bu nedenle güncel kılavuzlar, AI modellerinin geliştirilmesi ve raporlanması sürecinde veri seti bileşiminin şeffaf biçimde açıklanmasını ve potansiyel bias kaynaklarının açıkça tartışılmasını önermektedir (IEEE Global Initiative, 2020; Schwendicke ve ark., 2020).

2.4. Yapay Zekânın Temel Teknik Altyapısı

Ortodontide AI uygulamalarının doğru biçimde anlaşılabilmesi ve klinik olarak güvenli şekilde kullanılabilmesi için, bu sistemlerin dayandığı temel teknik altyapının bilinmesi büyük önem taşır. Makine öğrenmesi ve derin öğrenme temelli modeller, farklı matematiksel ve hesaplamalı prensiplere dayanmakta; her bir yaklaşımın güçlü ve sınırlı yönleri bulunmaktadır. Bu bölümde, ortodontik AI uygulamalarının arka planını oluşturan temel teknik kavramlar sistematik biçimde ele alınmaktadır (Bishop, 2019; Goodfellow ve ark., 2016).

2.4.1. Makine Öğrenmesi (Machine Learning, ML)

Makine öğrenmesi, bilgisayar sistemlerinin açık biçimde programlanmış kurallar olmaksızın, verilerden örüntüler öğrenmesini sağlayan algoritmalar bütünüdür. Bu yaklaşımda amaç, geçmiş verilerden elde edilen ilişkileri kullanarak yeni ve daha önce görülmemiş veriler için tahminler üretebilmektir (Bishop, 2019).

Ortodontide makine öğrenmesi algoritmaları, genellikle yapılandırılmış sayısal verilerin analizinde kullanılmaktadır. Sefalometrik ölçümler, ark uzunluğu değerleri, diş boyutları ve tedavi

süresi gibi nicel parametreler, ML modelleri için uygun girdi türleridir (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

Ortodontik çalışmalarda sık kullanılan makine öğrenmesi algoritmaları şunlardır:

- karar ağaçları (decision trees),
- rastgele ormanlar (random forest),
- destek vektör makineleri (support vector machines),
- k-en yakın komşu algoritmaları (k-nearest neighbors),
- lojistik regresyon.

Bu yöntemler, özellikle ekstraksiyon kararlarının desteklenmesi ve tedavi süresi tahmini gibi görevlerde klinisyenlerle uyumlu sonuçlar üretebilmektedir (Mason ve ark., 2023; Köktürk ve ark., 2024; Koletsi ve ark., 2021). Ancak geleneksel makine öğrenmesi yaklaşımları, görüntü temelli karmaşık verilerde manuel özellik çıkarımı gerektirdiğinden, performans açısından sınırlı kalabilmektedir.

2.4.2. Derin Öğrenme (Deep Learning, DL)

Derin öğrenme, makine öğrenmesinin çok katmanlı yapay sinir ağlarına dayanan ileri bir alt dalıdır. Derin öğrenme algoritmalarının en önemli özelliği, verilerden otomatik olarak anlamlı özellikleri çıkarabilmesi ve bu sayede insan müdahalesine duyulan ihtiyacı azaltmasıdır (Goodfellow ve ark., 2016).

Ortodonti pratiğinde üretilen verilerin büyük bölümünün görüntü temelli olması, derin öğrenme yaklaşımlarını özellikle cazip hâle getirmiştir. Lateral sefalometrik radyografiler, panoramik

görüntüler, CBCT kesitleri ve dijital dental modeller, derin öğrenme ağlarının etkin biçimde kullanılabildiği veri türleridir (Gokdeniz & Kamburoğlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023).

Derin öğrenme tabanlı sistemler, otomatik landmark tespiti, diş ve kök segmentasyonu, iskeletsel patern sınıflandırması ve tedavi sonucu öngörüsü gibi alanlarda geleneksel yöntemlere kıyasla daha yüksek doğruluk gösterebilmektedir (Gracea ve ark., 2025).

2.4.3. Konvolüsyonel Sinir Ağları (Convolutional Neural Networks, CNN)

Konvolüsyonel sinir ağları, görüntü işleme görevleri için özel olarak tasarlanmış derin öğrenme mimarileridir. CNN'ler, görüntüleri piksel düzeyinde analiz ederek kenar, doku ve şekil gibi hiyerarşik özellikleri otomatik olarak öğrenir (He ve ark., 2016).

Ortodontide CNN tabanlı modeller, özellikle sefalometrik landmarkların otomatik tespiti alanında yaygın biçimde kullanılmaktadır. Park J. ve ark. (2019), CNN tabanlı bir sistemin manuel sefalometrik ölçümlerle klinik olarak kabul edilebilir düzeyde uyum gösterdiğini bildirmiştir. Benzer şekilde panoramik radyografilerde diş numaralandırma ve gömülü diş tespiti gibi görevlerde de CNN mimarileri yüksek performans sergilemektedir (Jeong ve ark., 2021; Nan ve ark., 2023).

Bununla birlikte CNN performansı, eğitim verisinin miktarı ve kalitesiyle doğrudan ilişkilidir. Düşük çözünürlüklü görüntüler,

artefaktlar ve cihazlar arası farklılıklar model başarısını olumsuz etkileyebilmektedir (Litjens ve ark., 2017).

2.4.4. Transfer Learning

Transfer learning, daha önce büyük veri setleri üzerinde eğitilmiş bir derin öğrenme modelinin, farklı fakat ilişkili bir görev için yeniden kullanılmasını sağlayan bir yaklaşımdır. Bu yöntem, özellikle sınırlı veri setlerinin bulunduğu klinik alanlarda model performansını artırmak için yaygın olarak tercih edilmektedir (Bishop, 2019).

Ortodontide transfer learning, küçük ölçekli radyografik veri setleriyle yapılan çalışmalarda önemli avantajlar sunmaktadır. Önceden eğitilmiş ağlar kullanılarak geliştirilen modellerin, sıfırdan eğitilen modellere kıyasla daha hızlı yakınsadığı ve daha yüksek doğruluk elde ettiği bildirilmiştir (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

Bu yaklaşım, nadir görülen anomaliler ve özel hasta gruplarına yönelik AI uygulamalarında özellikle değerli kabul edilmektedir.

2.4.5. Açıklanabilir Yapay Zekâ (Explainable Artificial Intelligence, XAI)

AI sistemlerinin klinik ortamda kabul görmesinin önündeki en önemli engellerden biri, karar süreçlerinin “kara kutu” olarak algılanmasıdır. Açıklanabilir AI (XAI) yaklaşımları, modelin hangi girdilere dayanarak çıktı ürettiğini görselleştirmeyi ve yorumlanabilir hâle getirmeyi amaçlar (European Commission, 2019).

Ortodontide XAI uygulamaları, özellikle tedavi planlaması ve ekstraksiyon kararları gibi yüksek klinik risk içeren alanlarda önem kazanmaktadır. Görüntü üzerinde dikkat haritaları (saliency maps) ve özellik katkı analizleri sayesinde, klinisyenler model önerilerini daha bilinçli biçimde değerlendirebilmektedir (Gracea ve ark., 2025).

2.4.6. Yapay Zekâ Yazılımlarının Çalışma Prensipleri

Ortodontide kullanılan AI yazılımları, genellikle benzer bir iş akışı izler. Bu iş akışı aşağıdaki temel adımlardan oluşur:

- I. Verinin sisteme aktarılması (radyografi, dijital model, fotoğraf),
- II. Ön işleme (gürültü azaltma, normalizasyon),
- III. Otomatik özellik çıkarımı,
- IV. Sınıflandırma veya regresyon analizi,
- V. Sonuçların klinik rapor hâline getirilmesi.

Bu süreç, manuel analizlere kıyasla önemli ölçüde zaman kazancı sağlamakta ve ölçüm standardizasyonunu artırmaktadır. Ancak literatürde vurgulandığı üzere, otomatik olarak üretilen çıktılar hiçbir zaman klinisyenin değerlendirmesinin yerine geçmemeli; yalnızca destekleyici bir araç olarak kullanılmalıdır (Cabitza ve ark., 2017; Topol, 2019; American Dental Association, 2023).

2.5. Ortodontik Görüntülemeye Yapay Zekâ Uygulamaları

Ortodontik tanı ve tedavi planlamasında görüntüleme yöntemleri, klinik kararların temelini oluşturmaktadır. Lateral sefalometrik radyografiler, panoramik görüntüler, konik ışınlı bilgisayarlı tomografi (CBCT) kesitleri ve klinik fotoğraflar; dişlerin,

çenelerin ve yüz iskeletinin değerlendirilmesinde rutin olarak kullanılmaktadır. Bu görüntülerin manuel analizi zaman alıcı olabilmekte ve operatörler arası farklılıklara açık olmaktadır. AI tabanlı görüntü analiz sistemleri, bu süreci daha hızlı, tekrarlanabilir ve standart hâle getirmeyi amaçlamaktadır (Gokdeniz & Kamburoğlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023; Litjens ve ark., 2017).

Son yıllarda yayımlanan sistematik derlemeler, ortodontide AI uygulamalarının en yoğun olarak görüntüleme alanında geliştirildiğini ve klinik entegrasyona en yakın çözümlerin bu grupta yer aldığını göstermektedir (Liu ve ark., 2023a; 2023b).

Ortodontik görüntülemede AI uygulamaları; landmark tespiti, segmentasyon, sınıflandırma ve nicel ölçüm başlıkları altında yoğunlaşmaktadır. Bu alandaki çalışmaların büyük bölümünün tanı destek ve ön değerlendirme amaçlı olduğu, klinik entegrasyon ise validasyon süreçlerine bağlı olarak aşamalı ilerlemektedir. (Schwendicke ve ark., 2020; Koletsi ve ark., 2021).

2.5.1. İki Boyutlu Radyografilerde Yapay Zekâ

İki boyutlu radyografiler, ortodontik tanıda hâlen en yaygın kullanılan görüntüleme yöntemleridir. AI uygulamaları, bu görüntüler üzerinde otomatik analiz yapılabilmesini mümkün kılarak manuel ölçüm hatalarını azaltmayı hedeflemektedir (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

2.5.1.1. Lateral Sefalogram Analizi

Lateral sefalometrik radyografiler, iskeletsel ve dental ilişkilerin değerlendirilmesinde temel araçlardan biridir. Geleneksel sefalometrik analiz, anatomik landmarkların manuel olarak işaretlenmesini ve açısal–lineer ölçümlerin hesaplanmasını içerir. Bu süreç hem zaman alıcıdır hem de klinisyenin deneyimine bağlı olarak değişkenlik gösterebilir (Graber, 2016).

Derin öğrenme tabanlı konvolüsyonel sinir ağları (CNN), lateral sefalogramlarda anatomik landmarkların otomatik olarak tespit edilmesinde yaygın biçimde kullanılmaktadır. Park J. ve ark. (2019), CNN tabanlı bir modelin 19 sefalometrik landmarkı klinik olarak kabul edilebilir hata sınırları içinde belirleyebildiğini bildirmiştir. Takip eden çalışmalarda U-Net ve ResNet tabanlı mimarilerin doğruluğu daha da artırdığı gösterilmiştir (Hwang ve ark., 2020; Shin ve ark., 2021). Bununla birlikte, görüntü kalitesi, hasta pozisyonu ve yaşa bağlı anatomik varyasyonlar performansı etkileyen önemli faktörlerdir (Shin ve ark., 2021; Schwendicke ve ark., 2021).

Otomatik sefalometri sistemlerinin büyük bir avantajı, ölçümlerin standartlaştırılması ve analiz süresinin belirgin biçimde kısaltılmasıdır. Bununla birlikte literatürde, bu sistemlerin özellikle düşük kaliteli görüntülerde ve kraniofasiyal anomalilerin bulunduğu olgularda performans kaybı yaşayabileceği vurgulanmaktadır (Laitenberger ve ark., 2023).

2.5.1.2. Panoramik Radyografi Analizi

Panoramik radyografiler, dişlerin sürme durumu, kök gelişimi, gömülü dişler ve patolojik oluşumların değerlendirilmesinde önemli

bilgiler sunar. AI, panoramik görüntüler üzerinde otomatik diş numaralandırma, gömülü kanin tespiti ve kök morfolojisi analizi gibi görevlerde kullanılmaktadır (Bichu ve ark., 2021; ve ark., Ünal 2025).

Derin öğrenme tabanlı sistemlerin, panoramik radyografilerde gömülü kaninlerin tespitinde yüksek hassasiyet ve özgüllük değerlerine ulaşabildiği rapor edilmiştir. Bu tür uygulamalar, özellikle erken tanı ve tedavi planlaması açısından klinik fayda sağlamaktadır (Bichu ve ark., 2021; ve ark., Ünal 2025; Jeong ve ark., 2021; Nan ve ark., 2023).

Ancak panoramik görüntülerin iki boyutlu yapısı ve geometrik distorsiyonları, AI modellerinin doğruluğunu sınırlayan faktörler arasında yer almaktadır. Bu nedenle otomatik sonuçların klinisyen tarafından doğrulanması zorunludur (Cabitza ve ark., 2017; Topol, 2019; Gokdeniz & Kamburoğlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023).

2.5.2. Üç Boyutlu Görüntülemeye Yapay Zekâ

Üç boyutlu görüntüleme yöntemleri, ortodontide daha detaylı anatomik analiz yapılmasına olanak tanımaktadır. CBCT görüntülerinin yaygınlaşması, AI uygulamaları için yeni ve daha karmaşık bir veri alanı oluşturmuştur. AI, 3B görüntülerde manuel işlemleri otomatikleştirerek analiz süresini önemli ölçüde azaltmaktadır (Litjens ve ark., 2017).

2.5.2.1. CBCT Segmentasyonu

CBCT görüntülerinde dişlerin, köklerin ve alveolar kemiğin manuel olarak segmentasyonu oldukça zaman alıcıdır. Derin öğrenme

tabanlı segmentasyon algoritmaları, bu süreci otomatikleştirerek klinik iş yükünü azaltmayı hedeflemektedir (Wang ve ark., 2024; Zhou ve ark., 2025; Flügge ve ark., 2025).

CNN tabanlı segmentasyon modelinin diş ve kök yapılarını manuel segmentasyona yakın doğrulukla ayırabildiğini bildirilmiştir (Wang ve ark., 2024). Bu tür uygulamalar, özellikle kök rezorpsiyonu değerlendirmesi, alveolar kemik yüksekliği analizi ve ortognatik cerrahi planlaması açısından önemli avantajlar sunmaktadır (Hung ve ark., 2023).

Çok merkezli çalışmalarda, CBCT cihazları arasındaki görüntü farklılıklarının model performansını etkileyebildiği gösterilmiştir. Bu nedenle dış validasyon ve cihaz-agnostik model geliştirme yaklaşımları önerilmektedir (Gao ve ark., 2025).

2.5.2.2. Üç Boyutlu Landmark Tespiti

İki boyutlu sefalometrik analizlerin aksine, üç boyutlu landmark tespiti daha karmaşık algoritmalar gerektirir. AI tabanlı 3B landmark tespit sistemleri, yüz iskeleti ve dentofasiyal yapıların volumetrik analizini mümkün kılmaktadır (Schwendicke ve ark., 2021; Gao ve ark., 2025). Üç boyutlu landmark tespiti, iki boyutlu sefalometriye kıyasla daha fazla anatomik bilgi sunsa da teknik olarak daha zordur. AI, bu zorluğu aşmada önemli bir potansiyel göstermektedir. Ancak literatürde, 3B landmark tespitinde hata paylarının 2B'ye kıyasla daha yüksek olduğu bildirilmektedir (Schwendicke ve ark., 2021; Hung ve ark., 2023).

Bu alandaki çalışmalar, henüz araştırma aşamasında olmakla birlikte, 3B analizlerin cerrahi planlama ve büyüme-gelişim

değerlendirmelerinde gelecekte önemli bir rol oynayacağını göstermektedir (Gao ve ark., 2025).

2.5.3. Fotoğraf Tabanlı Görüntü Analizi

Klinik ve ekstraoral fotoğraflar, yüz estetiği ve yumuşak doku değerlendirmesinde önemli bir yere sahiptir. AI algoritmaları, yüz fotoğrafları üzerinden iskeletsel patern sınıflandırması, asimetri analizi ve profil değerlendirmesi gibi görevlerde kullanılmaktadır (Park W ve ark., 2021; Liu ve ark., 2023a; 2023b).

Fotoğraf tabanlı AI sistemlerinin en büyük avantajı, radyasyon içermemeleri ve uzaktan hasta takibine uygun olmalarıdır. Bu nedenle tele-ortodonti uygulamalarında yüz fotoğraflarının otomatik analizi giderek daha fazla ilgi görmektedir (Lo Giudice ve ark., 2022; Sangalli ve ark., 2024).

Bu sistemler, özellikle tele-ortodonti ve hasta iletişimi bağlamında klinik değere sahiptir. Ancak fotoğraf çekim koşulları ve ışıklandırma gibi değişkenler, performansı etkileyebilmektedir (Liu ve ark., 2023a; 2023b).

2.5.4. Görüntü İşlemede Klinik Katkıları

AI destekli görüntü analizi, ortodontik klinik iş akışında önemli katkılar sunmaktadır (Schwendicke ve ark., 2020). Otomatik ölçümler sayesinde analiz süresi kısaltmakta, operatörler arası varyasyon azalmakta ve hasta bilgilendirme süreci daha etkin hâle gelmektedir (Gracea ve ark., 2025).

Ayrıca standartlaştırılmış analizler, çok merkezli klinik çalışmaların yürütülmesini kolaylaştırmakta ve araştırma verilerinin karşılaştırılabilirliğini artırmaktadır (Liu ve ark., 2023a).

Bununla birlikte AI, klinik kararın yerine geçen bir mekanizma değil; karar destek aracı olarak konumlandırılmalıdır. Otomasyon yanlılığı riskinin farkında olunması, klinik güvenlik açısından kritiktir (Cabitza ve ark., 2017; Topol, 2019).

2.5.5. Görüntüleme Tabanlı Sınırlamalar

Tüm avantajlarına rağmen AI tabanlı görüntü analiz sistemlerinin önemli sınırlamaları bulunmaktadır. Görüntü kalitesindeki farklılıklar, metal artefaktları, cihazlar arası varyasyonlar ve veri seti bias'ı, model performansını olumsuz etkileyebilmektedir (Litjens ve ark., 2017).

Ortodontik görüntülemede AI uygulamalarının temel sınırlamaları; veri kalitesi, cihazlar arası farklılıklar ve yeterli dış validasyon eksikliğidir. Ayrıca radyasyon dozu nedeniyle CBCT kullanımının endikasyonlara uygun biçimde sınırlandırılması gerekmektedir (Hung ve ark., 2023).

Bu nedenle literatürde, AI destekli analizlerin mutlaka klinik uzman değerlendirmesiyle birlikte kullanılması gerektiği vurgulanmaktadır. AI, ortodontide bağımsız bir karar verici değil; klinisyeni destekleyen bir araç olarak konumlandırılmalıdır (Cabitza ve ark., 2017; Topol, 2019; American Dental Association, 2023).

Literatürde, görüntüleme tabanlı AI sistemlerinin klinik entegrasyonu için standartlaştırılmış veri setleri ve uzun dönemli

klirik değerdendirmelere ihtiya olduėu vurgulanmaktadır (European Orthodontic Society, 2024).

2.6. Dijital Dental Modellerde Yapay Zekâ

İntraoral tarayıcıların klinik kullanıma girmesiyle birlikte dijital dental modeller, ortodontik tanı ve tedavi planlamasının temel bileşenlerinden biri hâline gelmiştir. Alı modellerin yerini alan dijital modeller; yüksek çözünürlükte, üç boyutlu ve ölçülebilir veri sunmaları sayesinde hem klinik uygulamalarda hem de araştırma alanında geniş bir kullanım alanı bulmuştur. AI tabanlı algoritmalar, bu dijital modeller üzerinde otomatik analizler yaparak manuel ölçümlere olan bağımlılığı azaltmayı ve değerdendirmelerin standardizasyonunu sağlamayı amaçlamaktadır (Graber, 2016; Liu ve ark., 2023b; Tomášik ve ark., 2024).

Dijital dental modeller, ark formu, diş boyutları, dişlerin üç boyutlu konumları ve oklüzal ilişkiler gibi çok sayıda parametreyi aynı anda içeren karmaşık veri yapılarıdır. Bu çok boyutlu yapı, derin öğrenme ve makine öğrenmesi algoritmaları için uygun bir analiz ortamı sunmakta; ortodontik değerdendirmelerin daha objektif ve tekrarlanabilir biçimde yapılmasına olanak tanımaktadır (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

AI, dijital dental modeller üzerinde otomatik diş tanımlama, segmentasyon, ark formu analizi, crowding değerdendirmesi ve tedavi öncesi–sonrası karşılaştırmalar gibi görevlerde kullanılmaktadır. Sistematiğ derlemeler, bu alandaki çalışmaların doğruluk ve tekrarlanabilirlik açısından umut verici sonuçlar sunduğunu, ancak

klirik entegrasyonun validasyon srelerine baėlı olarak ilerlediėini gstermektedir (Liu ve ark., 2023a; 2023b).

2.6.1. Otomatik Diř Etiketleme

Dijital dental modeller zerinde gerekleřtirilen ilk ve en temel AI uygulamalarından biri, otomatik diř etiketleme sistemleridir. Bu sistemler, her bir diři otomatik olarak tanımlayarak numaralandırmayı ve anatomik sınıflandırmayı hedefler. Geleneksel yntemlerde bu iřlem manuel olarak yapılmakta ve operatr deneyimine baėlı olarak deėiřkenlik gsterebilmektedir (Liu ve ark., 2023b; Tomášik ve ark., 2024).

Derin ėrenme tabanlı algoritmalar, diřlerin morfolojik zelliklerini ve komřuluk iliřkilerini analiz ederek yksek doėrulukta etiketleme yapabilmektedir. Yapılan alıřmalarda, otomatik diř etiketleme sistemlerinin %95'in zerinde doėruluk oranlarına ulařabildiėi ve klinik kullanım iin yeterli performans gsterdiėi bildirilmiřtir (Gokdeniz & Kamburoėlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023; Wang ve ark., 2024; Zhou ve ark., 2025; Flgge ve ark., 2025).

Otomatik etiketleme, dijital model analizinin sonraki ařamaları iin kritik bir adımdır. Diřlerin doėru tanımlanması; crowding analizi, ark uzunluėu hesaplamaları ve tedavi simlasyonlarının gvenilirliėi aısından temel neme sahiptir.

Literatrde, otomatik diř etiketleme sistemlerinin manuel etiketlemeye kıyasla hem zaman tasarrufu saėladıėı hem de operatr kaynaklı hataları azalttıėı bildirilmektedir. Bununla birlikte, eksik

dişler, restorasyonlar ve aşırı çapraşıklık gibi durumların model performansını etkileyebileceği vurgulanmaktadır (Thanathornwong, 2018).

2.6.2. Diş Segmentasyonu

Diş segmentasyonu, dijital dental modellerde her bir dişin çevre dokulardan ve komşu dişlerden ayrıştırılmasını ifade eder. AI destekli segmentasyon algoritmaları, bu işlemi otomatikleştirerek manuel modelleme ihtiyacını önemli ölçüde azaltmaktadır (Hung ve ark., 2023).

Konvolüsyonel sinir ağları ve U-Net tabanlı mimariler, diş segmentasyonunda en sık kullanılan derin öğrenme yaklaşımlarıdır. Bu modeller, diş yüzeylerinin geometrik özelliklerini analiz ederek hassas sınır tespiti yapabilmektedir. Literatürde, AI tabanlı segmentasyonun manuel segmentasyona kıyasla benzer doğrulukta ancak çok daha kısa sürede tamamlandığı rapor edilmiştir (Wang ve ark., 2024; Zhou ve ark., 2025; Flügge ve ark., 2025).

Diş segmentasyonu, özellikle clear aligner tedavilerinde ve dijital set-up planlamasında kritik bir rol oynamaktadır. Segmentasyon hataları, diş hareket simülasyonlarını ve aparey üretimini doğrudan etkileyebileceğinden, bu sistemlerin klinik doğruluğu büyük önem taşır (Liu ve ark., 2023b; Wong ve ark., 2023).

2.6.3. Crowding Analizi

Crowding analizi, ortodontik tanının en temel bileşenlerinden biridir ve diş boyutları ile ark uzunluğu arasındaki ilişkiye dayanır. Dijital dental modeller üzerinde yapılan crowding değerlendirmeleri,

manuel yöntemlere kıyasla daha hassas ölçümler yapılmasına olanak tanımaktadır (Graber, 2016).

AI tabanlı crowding analiz sistemleri, diş genişliklerini otomatik olarak ölçmekte ve ark uzunluğu ile karşılaştırarak yer darlığı miktarını hesaplamaktadır. Yapılan çalışmalarda, bu sistemlerin manuel ölçümlerle yüksek uyum gösterdiği ve ölçüm tekrarlanabilirliğini artırdığı bildirilmiştir (Real ve ark., 2022; Hong ve ark., 2022).

Crowding analizinin otomatik hâle getirilmesi, tedavi planlamasında zaman kazancı sağlamakta ve ekstraksiyon kararlarının daha objektif biçimde desteklenmesine katkı sunmaktadır (Mason ve ark., 2023; Köktürk ve ark., 2024).

2.6.4. Ark Formu Analizi

Ark formu, ortodontik tedavinin estetik ve fonksiyonel başarısını doğrudan etkileyen önemli bir parametredir. Dijital dental modeller üzerinde ark formunun değerlendirilmesi, AI algoritmaları sayesinde daha standart ve karşılaştırılabilir hâle gelmiştir (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

Makine öğrenmesi ve derin öğrenme yaklaşımları, ark formunu matematiksel modeller aracılığıyla sınıflandırabilmekte ve bireyselleştirilmiş ark formlarının tanımlanmasına olanak tanımaktadır. Bu sistemler, tedavi öncesi ve sonrası ark değişikliklerinin nicel olarak değerlendirilmesini de mümkün kılmaktadır (Liu ve ark., 2023b; Tomášik ve ark., 2024).

Ark formu analizinde AI'nın kullanımı, özellikle aligner tedavilerinde ve ark genişletme stratejilerinin planlanmasında klinik açıdan önemli katkılar sunmaktadır (Liu ve ark., 2023b; Wong ve ark., 2023).

2.6.5. Tedavi Öncesi–Sonrası Model Karşılaştırmaları

Dijital dental modeller, tedavi öncesi ve sonrası durumun karşılaştırılmasına olanak tanıyan güçlü bir değerlendirme aracıdır. AI destekli model karşılaştırma algoritmaları, diş pozisyonlarındaki değişimleri otomatik olarak analiz ederek tedavi sonuçlarının objektif biçimde değerlendirilmesini sağlamaktadır (Gracea ve ark., 2025).

Bu tür sistemler, diş hareketlerinin miktarını ve yönünü üç boyutlu olarak hesaplayabilmekte; böylece planlanan ve gerçekleşen tedavi sonuçları arasındaki farklar nicel olarak ortaya konabilmektedir. Bu yaklaşım, tedavi başarısının değerlendirilmesinde ve gelecekteki tedavi planlarının optimize edilmesinde önemli bir rol oynamaktadır (Gracea ve ark., 2025).

2.6.6. İntraoral Tarayıcı Verilerinin Analizi

İntraoral tarayıcılar tarafından elde edilen verilerin doğruluğu ve güvenilirliği, AI uygulamalarının başarısını doğrudan etkilemektedir. AI algoritmaları, tarama sırasında oluşabilecek artefaktları ve eksik veri bölgelerini otomatik olarak tespit edebilmekte ve veri kalitesini artırmaya yönelik düzeltmeler önerebilmektedir (Gokdeniz & Kamburoğlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023).

Ayrıca bazı gelişmiş sistemler, tarama verilerinden elde edilen bilgilerle oklüzal temas analizi ve diş aşınma değerlendirmesi gibi ileri analizler yapabilmektedir. Bu tür uygulamalar, dijital dental modellerin klinik değerini daha da artırmaktadır (Hung ve ark., 2023).

Bununla birlikte intraoral tarayıcı verilerinin cihazlar arası farklılıklar gösterebildiği ve bu durumun AI modellerinin genellenebilirliğini etkileyebileceği unutulmamalıdır. Bu nedenle çok merkezli veri setleriyle geliştirilen modeller, klinik kullanım açısından daha güvenilir kabul edilmektedir (Cabitza ve ark., 2017; Topol, 2019).

2.7. Tedavi Planlamasında Yapay Zekâ

Ortodontik tedavi planlaması; tanısal verilerin sentezlenmesi, biyomekanik prensiplerin değerlendirilmesi ve hastaya özgü faktörlerin dikkate alınmasını gerektiren karmaşık bir süreçtir. Geleneksel yaklaşımda bu süreç büyük ölçüde klinisyenin deneyimine dayanmakta, benzer vakalar arasında dahi farklı tedavi kararları alınabilmektedir. AI tabanlı karar destek sistemleri, çok sayıda klinik ve görüntüleme verisini eş zamanlı olarak analiz ederek tedavi planlamasının daha objektif, tutarlı ve öngörülebilir hâle getirilmesini amaçlamaktadır (Schwendicke ve ark., 2020; Gracea ve ark., 2025).

Son yıllarda yayımlanan çalışmalar, AI'nın ortodontik tedavi planlamasında özellikle sınıflandırma, risk değerlendirmesi ve sonuç tahmini alanlarında anlamlı katkılar sunduğunu göstermektedir. Ancak bu sistemlerin klinik kabulü, yalnızca doğruluk değerlerine değil; aynı

zamanda açıklanabilirlik, güvenilirlik ve klinik entegrasyon düzeyine de bağlıdır (Cabitza ve ark., 2017; Topol, 2019).

2.7.1. Maloklüzyon Sınıflandırması

Maloklüzyonun doğru sınıflandırılması, ortodontik tedavi planlamasının ilk ve en kritik adımlarından biridir. Angle sınıflaması, iskeletsel patern analizi ve vertikal yön değerlendirmeleri, tedavi stratejisinin belirlenmesinde temel rol oynar. AI tabanlı sınıflandırma modelleri, sefalometrik ölçümler, yüz fotoğrafları ve radyografik verileri kullanarak maloklüzyon tiplerini otomatik olarak belirleyebilmektedir (Jeong ve ark., 2021; Nan ve ark., 2023; Park W ve ark., 2021).

Derin öğrenme tabanlı modellerin, özellikle iskeletsel Sınıf I, II ve III vakaların ayrımında yüksek doğruluk gösterdiği rapor edilmiştir. Bu sistemler, operatörler arası farklılıkları azaltarak tanısal standardizasyon sağlamaktadır (Park W ve ark., 2021; Liu ve ark., 2023a; 2023b).

Bununla birlikte karmaşık ve sınır vakalarda, otomatik sınıflandırmanın tek başına yeterli olmadığı ve klinik değerlendirme ile birlikte ele alınması gerektiği belirtilmektedir.

2.7.2. Ekstraksiyon Kararlarının Desteklenmesi

Ekstraksiyon kararı, ortodontik tedavi planlamasında en tartışmalı ve geri dönüşü zor kararlardan biridir. Bu karar; crowding miktarı, profil analizi, iskeletsel yapı ve yumuşak doku özellikleri gibi çok sayıda değişkenin birlikte değerlendirilmesini gerektirir (Graber, 2016).

Makine öğrenmesi modelleri, geçmiş hasta verilerinden öğrenerek ekstraksiyon gerekliliğini öngörmeye yönelik karar destek sistemleri geliştirilmesini mümkün kılmıştır; hatta, random forest ve destek vektör makineleri kullanılarak geliştirilen modellerin, deneyimli ortodontistlerin kararlarıyla yüksek uyum gösterdiği bildirilmiştir (Mason ve ark., 2023; Köktürk ve ark., 2024).

Bu tür sistemler, özellikle genç klinisyenler için eğitsel bir destek aracı olarak değer taşımaktadır. Ancak literatürde, AI'nın ekstraksiyon kararını “vermesi” değil; klinisyenin karar sürecini desteklemesi gerektiği açıkça vurgulanmaktadır (Cabitza ve ark., 2017; Topol, 2019).

2.7.3. Tedavi Zorluk Derecesinin Tahmini

Tedavi zorluk derecesinin önceden tahmin edilmesi hem klinik planlama hem de hasta bilgilendirme açısından büyük önem taşır. AI tabanlı modeller, başlangıç maloklüzyon şiddeti, diş dizilimi, iskeletsel ilişkiler ve planlanan hareket miktarlarını analiz ederek tedavi zorluk seviyesini öngörebilmektedir (Koletsis ve ark., 2021).

Bu tür sistemler, vaka seçimi ve sevk kararlarında da klinisyene rehberlik edebilir. Özellikle kompleks vakaların erken aşamada belirlenmesi, tedavi sürecinde karşılaşılabilecek risklerin daha iyi yönetilmesine katkı sağlamaktadır (Liu ve ark., 2023b; Wong ve ark., 2023).

2.7.4. Aparey Seçiminde Yapay Zekâ

Ortodontik tedavide sabit apareyler, fonksiyonel apareyler ve clear aligner sistemleri arasında doğru seçimin yapılması, tedavi

başarısını doğrudan etkiler. AI, hastaya ait klinik ve dijital verileri analiz ederek hangi aparey tipinin daha uygun olabileceğine dair öngörüler sunabilmektedir (Liu ve ark., 2023b; Tomášik ve ark., 2024).

Bazı çalışmalar, AI tabanlı sistemlerin aligner tedavisi için uygun vaka seçiminde deneyimli klinisyenlerle benzer doğruluk düzeylerine ulaşabildiğini bildirmiştir. Bu durum, özellikle hasta beklentilerinin yönetilmesi ve tedavi seçeneklerinin objektif biçimde sunulması açısından önemlidir (Gracea ve ark., 2025).

2.7.5. Kişiselleştirilmiş Tedavi Önerileri

AI'nın ortodontik tedavi planlamasındaki en önemli potansiyellerinden biri, kişiselleştirilmiş tedavi yaklaşımlarını desteklemesidir. AI modelleri, büyük hasta veri setlerinden öğrenerek belirli hasta profilleri için daha başarılı tedavi stratejilerini önerebilmektedir (Topol, 2019).

Bu yaklaşım, “tek tip tedavi” anlayışından uzaklaşarak, hastaya özgü biyolojik ve morfolojik özelliklerin daha fazla dikkate alındığı bir planlama sürecine olanak tanımaktadır. Ancak kişiselleştirilmiş önerilerin güvenilirliği, kullanılan veri setlerinin çeşitliliği ve model validasyonunun kalitesiyle doğrudan ilişkilidir (European Orthodontic Society, 2024).

2.7.6. Klinik Karar Sürecine Entegrasyon

AI destekli tedavi planlama sistemlerinin klinik pratikte etkin biçimde kullanılabilmesi için, bu sistemlerin iş akışına sorunsuz şekilde entegre edilmesi gerekmektedir. Klinik yazılımlarla uyumlu

çalışan ve sonuçlarını açık biçimde sunan sistemler, klinisyen tarafından daha kolay benimsenmektedir (American Dental Association, 2023).

Bununla birlikte literatürde, “automation bias” riskine dikkat çekilmektedir. Klinik uzmanların, AI önerilerine aşırı güvenmesi hatalı kararların fark edilmeden uygulanmasına yol açabilir. Bu nedenle AI çıktılarının her zaman klinik değerlendirme ile birlikte ele alınması gerektiği vurgulanmaktadır (Cabitza ve ark., 2017; Topol, 2019; European Commission, 2019).

2.8. Clear Aligner Sistemleri ve Yapay Zekâ

Clear aligner sistemleri, dijital planlama ve seri üretime dayalı yapıları nedeniyle AI uygulamaları için en uygun ortodontik tedavi yöntemlerinden biri olarak kabul edilmektedir. Aligner tedavisinde tüm diş hareketleri, tedaviye başlanmadan önce dijital ortamda planlanmakta ve bu plan doğrultusunda ardışık apareyler üretilmektedir. Bu süreç, AI algoritmalarının büyük veri setlerinden öğrenerek tedavi planlarını optimize edebilmesine olanak tanımaktadır (Tomášik ve ark., 2024; Liu ve ark., 2023b; Wong ve ark., 2023).

Geleneksel aligner planlamasında, dijital set-up büyük ölçüde teknisyen ve klinisyenin deneyimine dayanırken; AI destekli sistemler geçmiş tedavi verilerini analiz ederek daha öngörülebilir ve standart planlamalar sunmayı amaçlamaktadır. Bu durum, özellikle tedavi süresinin kısaltılması ve refinement ihtiyacının azaltılması açısından klinik önem taşımaktadır (Koletsı ve ark., 2021).

2.8.1. Aligner Planlamasında Yapay Zekâ Kullanımı

Aligner tedavisinde dijital planlama, her bir dişin üç boyutlu hareketinin ve bu hareketlerin sırasının belirlenmesini içerir. AI tabanlı planlama algoritmaları, daha önce tedavi edilmiş binlerce vakanın verilerini analiz ederek hangi diş hareketlerinin klinik olarak daha öngörülebilir olduğunu belirleyebilmektedir (Gracea ve ark., 2025).

Bu sistemler, planlanan hareketlerin biyomekanik sınırlar içinde kalmasını sağlayarak aşırı rotasyon, intrüzyon veya translasyon gibi riskli hareketleri önceden tespit edebilmektedir. Böylece başlangıç set-up'ının daha gerçekçi ve klinik olarak uygulanabilir hâle gelmesi sağlanmaktadır (Liu ve ark., 2023b; Wong ve ark., 2023).

2.8.2. Diş Hareketlerinin Öngörülmesi

Clear aligner tedavisinde planlanan diş hareketlerinin klinik olarak ne ölçüde gerçekleşeceği, tedavi başarısını belirleyen temel faktörlerden biridir. AI modelleri, diş tipi, kök morfolojisi, hareket yönü ve miktarı gibi değişkenleri analiz ederek diş hareketlerinin öngörülebilirliğini tahmin edebilmektedir (Koletsi ve ark., 2021).

Yapılan çalışmalarda, AI destekli sistemlerin özellikle tipping ve translasyon hareketlerinin başarısını daha doğru tahmin edebildiği; buna karşılık rotasyon ve intrüzyon gibi karmaşık hareketlerde öngörü doğruluğunun daha düşük olabildiği bildirilmiştir (Liu ve ark., 2023b; Wong ve ark., 2023). Bu bilgiler, tedavi planlamasında hareketlerin daha konservatif biçimde düzenlenmesine katkı sağlamaktadır.

2.8.3. Refinement İhtiyacının Tahmini

Refinement, clear aligner tedavilerinde sık karşılaşılan bir durumdur ve tedavi süresinin uzamasına neden olabilmektedir. AI tabanlı tahmin modelleri, tedavi başlangıcındaki maloklüzyon şiddeti, planlanan diş hareketleri ve hasta uyumu gibi parametreleri dikkate alarak refinement ihtiyacını önceden öngörmeye çalışmaktadır (Volovic ve ark., 2023).

Bu tür öngörüler, klinisyenin hasta bilgilendirme sürecini daha gerçekçi biçimde yürütmesine ve tedavi planını buna göre düzenlemesine olanak tanımaktadır. Literatürde, AI destekli planlamaların daha az refinement ile sonuçlanabildiğini bildiren çalışmalar mevcuttur (Liu ve ark., 2023b; Tomášik ve ark., 2024).

2.8.4. Set-up Optimizasyonu

Set-up optimizasyonu, clear aligner tedavisinde dijital planlamanın en kritik aşamalarından biridir. AI, planlanan diş hareketlerini biyomekanik ve klinik açıdan analiz ederek set-up'ın optimize edilmesini sağlamaktadır. Bu optimizasyon, hem diş hareketlerinin başarısını artırmakta hem de aparey sayısının azaltılmasına katkı sunmaktadır (Gracea ve ark., 2025).

Derin öğrenme tabanlı modeller, geçmiş vakalardaki planlanan ve gerçekleşen hareketler arasındaki farkları analiz ederek, gelecekteki set-up'lar için düzeltici öneriler geliştirebilmektedir. Bu yaklaşım, aligner tedavilerinde daha öngörülebilir sonuçlar elde edilmesine yardımcı olmaktadır (Liu ve ark., 2023b; Wong ve ark., 2023).

2.8.5. Aligner Tedavilerinde Klinik Sınırlar

Her ne kadar AI clear aligner planlamasında önemli avantajlar sunsa da, bu sistemlerin mutlak doğruluk sağlamadığı unutulmamalıdır. Diş hareketlerinin biyolojik yanıtları bireyler arasında farklılık gösterebilmekte ve hasta uyumu, tedavi başarısında belirleyici rol oynamaktadır (Cabitza ve ark., 2017; Topol, 2019).

Ayrıca mevcut AI modellerinin büyük bir bölümü, belirli ticari sistemlere ait veri setleriyle eğitildiğinden, farklı aligner markaları ve klinik protokoller için genellenebilirlik sınırlı olabilir. Bu nedenle AI önerilerinin her zaman klinik deneyim ve biyomekanik bilgi ile birlikte değerlendirilmesi gerekmektedir (European Orthodontic Society, 2024).

2.9. Tedavi Süresi ve Sonuç Tahmini

Ortodontik tedavi süresinin ve tedavi sonucunun önceden tahmin edilmesi, hem klinik planlama hem de hasta beklentilerinin yönetimi açısından büyük önem taşır. Geleneksel yaklaşımlar, tedavi süresini öngörmede klinik deneyime ve sınırlı sayıda değişkene dayanırken; AI tabanlı modeller, çok sayıda klinik, demografik ve dijital parametreyi eş zamanlı olarak analiz edebilme kapasitesi sayesinde daha kapsamlı ve nicel tahminler sunabilmektedir (Koletsı ve ark., 2021; Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

Ortodontik literatürde tedavi süresi ve sonuç tahmini alanındaki AI çalışmaları, genellikle regresyon ve sınıflandırma temelli modeller üzerinden yürütülmektedir. Bu modeller, tedavi

sürecine etki eden faktörlerin göreceli önemini ortaya koyarak klinik karar sürecine destek sağlamaktadır (Volovic ve ark., 2023).

2.9.1. Tedavi Süresi Tahmin Modelleri

Tedavi süresi tahmini için geliştirilen AI modelleri; hastanın yaşı, cinsiyeti, maloklüzyon tipi, iskeletsel patern, crowding miktarı, ekstraksiyon kararı, kullanılan aparey tipi ve tedavi sırasında uygulanan yardımcı mekanikler gibi çok sayıda değişkeni birlikte değerlendirmektedir (Koletsı ve ark., 2021).

Makine öğrenmesi tabanlı yaklaşımlar arasında random forest, gradient boosting ve destek vektör regresyonu gibi algoritmalar öne çıkmaktadır. Makine öğrenmesi ile geliştirilen bir modelin tedavi süresini ortalama ± 3 ay hata payı ile tahmin edebildiği bildirmilmiştir (Volovic ve ark., 2023). Bu hata aralığı, klinik uygulama açısından kabul edilebilir sınırlar içerisinde değerlendirilmektedir.

Bu tür modellerin önemli bir avantajı, değişkenler arasındaki doğrusal olmayan ilişkileri yakalayabilmesidir. Böylece geleneksel lineer regresyon modellerine kıyasla daha gerçekçi tahminler elde edilebilmektedir (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

2.9.2. Tedavi Sonucu Öngörü Algoritmaları

AI, yalnızca tedavi süresini değil; tedavi sonucunun başarısını öngörmeye yönelik olarak da kullanılmaktadır. Tedavi sonucu öngörü modelleri, başlangıç sefalometrik ölçümler, dijital model analizleri ve yüz fotoğraflarından elde edilen verileri kullanarak tedavi sonunda

ulaşılabilecek sonuçlara dair tahminler üretmektedir (Shin ve ark., 2021).

Bazı çalışmalar, AI tarafından öngörülen sonuçların, tedavi sonunda elde edilen gerçek sonuçlarla anlamlı korelasyon gösterdiğini raporlamıştır. Bu durum, özellikle tedavi hedeflerinin belirlenmesi ve alternatif tedavi senaryolarının değerlendirilmesi açısından klinik değer taşımaktadır (Gracea ve ark., 2025).

Ancak mevcut algoritmaların büyük bir bölümü, kısa dönem sonuçlara odaklanmakta; uzun dönem stabilite ve relaps riskine ilişkin öngörüler sınırlı kalmaktadır. Bu alan, gelecekteki araştırmalar için önemli bir gelişim potansiyeli sunmaktadır.

2.9.3. Hasta Beklentilerinin Yönetimi

Tedavi süresi ve sonuç tahmini, hasta–hekim iletişiminin önemli bir bileşenidir. AI destekli tahminler, hastalara tedavi süreci hakkında daha somut ve nicel bilgiler sunulmasını mümkün kılmaktadır. Bu durum, hasta beklentilerinin daha gerçekçi biçimde şekillenmesine ve tedaviye uyumun artmasına katkı sağlamaktadır (Topol, 2019).

Bununla birlikte literatürde, AI tarafından sunulan tahminlerin kesinlik içermediğinin hastaya açıkça ifade edilmesi gerektiği vurgulanmaktadır. Aksi takdirde, öngörülen süreden sapmalar hasta memnuniyetini olumsuz etkileyebilir ve hukuki sorunlara yol açabilir (Cabitza ve ark., 2017; Topol, 2019).

2.9.4. Tahmin Sistemlerinin Klinik Değeri

Tedavi süresi ve sonuç tahmin sistemlerinin klinik değeri, yalnızca doğruluk oranlarıyla değil; klinik karar sürecine sağladığı katkıyla değerlendirilmelidir. AI destekli tahminler, klinisyenin vaka planlamasını optimize etmesine ve kaynak yönetimini daha etkin biçimde yapmasına yardımcı olabilmektedir (Koletsis ve ark., 2021).

Ayrıca bu sistemler, klinik araştırmalarda hasta gruplarının daha homojen biçimde sınıflandırılmasına ve tedavi protokollerinin karşılaştırılmasına da katkı sunmaktadır. Bu yönüyle AI, yalnızca klinik pratikte değil; akademik araştırmalarda da değerli bir araç olarak değerlendirilmektedir (Bichu ve ark., 2021; 2025; Dipalma ve ark., 2023; Polizzi ark., 2025).

2.9.5. Süre Tahmininde Sınırlayıcı Faktörler

Her ne kadar AI tabanlı tahmin modelleri önemli avantajlar sunsa da, bu sistemlerin çeşitli sınırlamaları bulunmaktadır. Hasta uyumu, biyolojik yanıt farklılıkları ve tedavi sırasında ortaya çıkabilecek beklenmeyen klinik durumlar, tahmin doğruluğunu olumsuz etkileyebilmektedir (Cabitza ve ark., 2017; Topol, 2019).

Ayrıca mevcut modellerin çoğu, retrospektif ve tek merkezli veri setleriyle geliştirilmiştir. Bu durum, farklı popülasyonlarda ve klinik protokollerde genellenebilirliği sınırlayabilir. Bu nedenle literatürde, çok merkezli ve prospektif çalışmalarla geliştirilen modellerin klinik kullanım açısından daha güvenilir olacağı vurgulanmaktadır (European Orthodontic Society, 2024).

Sonuç olarak AI, tedavi süresi ve sonuç tahmininde güçlü bir destek aracı olmakla birlikte; klinik kararların yerini alan bağımsız bir sistem olarak değil, klinisyenin deneyimini tamamlayan bir teknoloji olarak konumlandırılmalıdır.

2.10. Ortodontik Biyomekanik, FEA ve Yapay Zekâ

Ortodontik tedavinin başarısı, dişlere uygulanan kuvvetlerin periodontal ligament, alveolar kemik ve diş kökleri üzerindeki biyomekanik etkilerinin doğru biçimde anlaşılmasına bağlıdır. Geleneksel biyomekanik yaklaşımlar, klinik gözlem ve deneysel çalışmalarla şekillenmiş olsa da bireysel hasta farklılıklarını nicel olarak modellemekte sınırlı kalmıştır. Sonlu elemanlar analizi (*Finite Element Analysis*, FEA), bu noktada diş hareketlerinin biyomekanik simülasyonunu mümkün kılan güçlü bir sayısal yöntem olarak ortodontide önemli bir yer edinmiştir (Wu ve ark., 2018).

AI, FEA tabanlı biyomekanik analizlerin daha hızlı, ölçeklenebilir ve kişiselleştirilmiş hâle getirilmesine olanak tanıyarak bu alanda yeni bir paradigma sunmaktadır. Özellikle yüksek hesaplama maliyetine sahip geleneksel FEA modellerinin AI ile desteklenmesi, klinik uygulamaya daha yakın çözümler geliştirilmesini mümkün kılmaktadır (Liu ve ark., 2023b; Wong ve ark., 2023).

2.10.1. Sonlu Elemanlar Analizinin (FEA) Ortodontideki Yeri

FEA, karmaşık biyolojik yapıların mekanik davranışlarını sayısal olarak modellemeye olanak tanıyan bir mühendislik

yöntemidir. Ortodontide FEA, diş–periodontal ligament–alveolar kemik kompleksinin kuvvetlere verdiği yanıtı simüle etmek amacıyla uzun süredir kullanılmaktadır (Wu ve ark., 2018).

Bu analizler sayesinde farklı kuvvet büyüklükleri, uygulama noktaları ve aparey tasarımlarının diş hareketi üzerindeki etkileri önceden değerlendirilebilmektedir. FEA çalışmaları, özellikle kök rezorpsiyonu riski, stres dağılımı ve optimal kuvvet kavramlarının anlaşılmasına önemli katkılar sağlamıştır (Koletsis ve ark., 2021).

Ancak geleneksel FEA modelleri, yüksek hesaplama gücü gerektirmeleri ve hasta bazında özelleştirilmelerinin zaman alıcı olması nedeniyle klinik rutinde sınırlı kullanım alanı bulmuştur.

2.10.2. Yapay Zekâ ve FEA Entegrasyonu

AI, FEA tabanlı biyomekanik analizlerin en önemli sınırlamalarından biri olan hesaplama süresini azaltma potansiyeline sahiptir. Derin öğrenme modelleri, daha önce oluşturulmuş FEA simülasyonlarından öğrenerek benzer biyomekanik senaryolar için hızlı tahminler üretebilmektedir (Wu ve ark., 2018; Yang ve ark., 2025; Wu ve ark., 2022).

Bu yaklaşımda AI, klasik FEA’nın yerini tamamen almak yerine, bir “hızlandırıcı” veya “yaklaştırmacı model” (surrogate model) olarak kullanılmaktadır. Böylece klinisyenler, farklı kuvvet senaryolarının olası biyomekanik sonuçlarını kısa sürede değerlendirebilmektedir (Liu ve ark., 2023b; Wong ve ark., 2023).

AI–FEA entegrasyonu, özellikle clear aligner biyomekaniği ve braket–tel sistemlerinde kuvvet dağılımının analizinde umut verici sonuçlar ortaya koymuştur.

2.10.3. Kişiselleştirilmiş Biyomekanik Modeller

Ortodontik biyomekanik yanıtlar, hastaya özgü anatomik ve biyolojik faktörlerden önemli ölçüde etkilenmektedir. Kemik yoğunluğu, kök uzunluğu, periodontal ligament kalınlığı ve alveolar kemik morfolojisi gibi değişkenler, diş hareketlerinin hızını ve yönünü belirleyen temel unsurlar arasında yer alır (Wu ve ark., 2018).

AI destekli biyomekanik modeller, bu bireysel farklılıkları dikkate alarak kişiselleştirilmiş tedavi planlamasına katkı sağlayabilir. AI modelleri, hasta bazlı görüntüleme ve klinik verileri kullanarak, standart biyomekanik varsayımların ötesine geçen öngörüler sunabilmektedir (Liu ve ark., 2023b; Wong ve ark., 2023; Tomášik ve ark., 2024).

Bu yaklaşım, “ortalama hasta” kavramı yerine bireyselleştirilmiş kuvvet ve aparey tasarımı anlayışını ön plana çıkarmaktadır.

2.10.4. Kuvvet Dağılımının Hızlı Tahmini

Ortodontik apareylerin uygulanması sırasında ortaya çıkan kuvvet dağılımının hızlı biçimde tahmin edilebilmesi, tedavi güvenliği açısından kritik öneme sahiptir. AI tabanlı modeller, karmaşık FEA hesaplamalarını saniyeler içinde yaklaşık olarak tahmin edebilme potansiyeline sahiptir (Wu ve ark., 2018; Yang ve ark., 2025; Wu ve ark., 2022).

Bu hızlı tahminler, klinisyenin tedavi planını uygulamadan önce olası riskleri değerlendirmesine olanak tanımaktadır. Özellikle yüksek stres birikimi görülebilecek bölgelerin önceden tespit edilmesi, kök rezorpsiyonu ve periodontal hasar riskinin azaltılmasına katkı sunabilir (Koletsis ve ark., 2021).

2.10.5. DeneySEL ve Klinik Sınırlamalar

Ortodontide FEA ve AI entegrasyonuna yönelik çalışmaların büyük bir bölümü hâlen dENEYSEL ve simülasyon temellidir. Biyolojik dokuların zamanla değişen adaptif yanıtları, mevcut modellerde yeterince temsil edilememektedir. Ayrıca periodontal ligamentin viskoelastik özellikleri ve bireysel biyolojik varyasyonlar, model doğruluğunu sınırlayan faktörler arasında yer almaktadır (Wu ve ark., 2018).

Literatürde, AI destekli biyomekanik modellerin klinik geçerliliğinin sağlanabilmesi için uzun dönemli, prospektif ve çok merkezli çalışmalara ihtiyaç olduğu vurgulanmaktadır. Bu nedenle bu sistemler, günümüzde klinik kararları belirleyen bağımsız araçlar olarak değil; araştırma ve karar destek amaçlı tamamlayıcı teknolojiler olarak değerlendirilmelidir (European Orthodontic Society, 2024).

2.11. Tele-Ortodonti İş Akışlarında Yapay Zekâ

Tele-ortodonti, dijital iletişim araçları ve uzaktan izleme teknolojileri aracılığıyla ortodontik bakımın mekânsal kısıtlarını azaltmayı amaçlayan bir yaklaşımdır. Özellikle pandemi sonrası dönemde hız kazanan bu model, hasta takibini kolaylaştırırken klinik iş yükünü de yeniden şekillendirmiştir. AI, tele-ortodonti sistemlerinin

etkinliğini artıran temel bileşenlerden biri olarak; otomatik değerlendirme, erken uyarı ve karar destek mekanizmaları sunmaktadır (Lo Giudice ve ark., 2022; Sangalli ve ark., 2024; American Dental Association, 2023).

Tele-ortodonti iş akışlarında AI'nın rolü, yüz yüze muayenenin yerini almak değil; rutin kontrollerin bir kısmını uzaktan ve güvenli biçimde yöneterek klinik kaynakların daha verimli kullanılmasını sağlamaktır. Bu bağlamda AI destekli sistemler, uygun vaka seçimi ve risk yönetimi açısından kritik öneme sahiptir (European Orthodontic Society, 2024).

2.11.1. Uzaktan Hasta Takibi

Uzaktan hasta takibi, tele-ortodontinin temel bileşenlerinden biridir. Hastaların belirli aralıklarla gönderdikleri ağız içi fotoğraflar, videolar veya tarama verileri, AI algoritmaları tarafından analiz edilerek tedavi ilerlemesi değerlendirilebilmektedir (Lo Giudice ve ark., 2022; Sangalli ve ark., 2024; Kelly ve ark., 2019; European Orthodontic Society, 2024).

AI destekli görüntü analiz sistemleri; diş dizilimindeki değişiklikleri, aligner uyumunu ve aparey hasarlarını otomatik olarak tespit edebilmektedir. Bu yaklaşım, klinisyenin yalnızca sorun tespit edilen vakalara müdahale etmesini sağlayarak zaman tasarrufu sunmaktadır (Liu ve ark., 2023b; Wong ve ark., 2023).

Ancak literatürde, uzaktan takip sistemlerinin özellikle karmaşık vakalarda ve büyüme-gelişim çağındaki hastalarda sınırlı kalabileceği vurgulanmaktadır. Bu nedenle uzaktan takip, uygun hasta

gruplarında ve belirli aralıklarla yüz yüze kontrollerle desteklenmelidir (Cabitza ve ark., 2017; Topol, 2019).

2.11.2. Akıllı Telefon Tabanlı Yapay Zekâ Sistemleri

Akıllı telefonların yaygınlaşması, tele-ortodonti uygulamalarının hasta tarafında erişilebilirliğini önemli ölçüde artırmıştır. Akıllı telefon tabanlı AI sistemleri, hastaların ev ortamında çektikleri fotoğraflar üzerinden otomatik analizler yapabilmektedir (Liu ve ark., 2023a; 2023b).

Bu sistemler; görüntü kalitesini otomatik olarak değerlendirme, uygun olmayan çekimleri eleme ve standart pozisyonlama hatalarını tespit etme gibi ön işlemleri de içermektedir. Böylece analiz sürecinde veri kalitesi artırılmakta ve yanlış değerlendirme riski azaltılmaktadır (Gokdeniz & Kamburoğlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023).

Akıllı telefon tabanlı AI uygulamaları, özellikle clear aligner tedavilerinde uzaktan takip için uygun bir altyapı sunmakta; hastaların tedaviye uyumunun izlenmesine katkı sağlamaktadır (Liu ve ark., 2023b; Wong ve ark., 2023).

2.11.3. Otomatik Uyarı Mekanizmaları

Tele-ortodonti sistemlerinde AI'nın en önemli katkılarından biri, otomatik uyarı mekanizmalarıdır. AI algoritmaları, uzaktan elde edilen verilerde belirli eşik değerleri aştığında klinisyeni otomatik olarak bilgilendirebilmektedir. Bu uyarılar; braket kopması, aligner

uyumsuzluğu, diş hareketinde beklenmeyen sapmalar veya oral hijyen sorunları gibi durumları kapsayabilir (Koletsis ve ark., 2021).

Otomatik uyarı sistemleri, olası komplikasyonların erken dönemde fark edilmesine ve zamanında müdahale edilmesine olanak tanımaktadır. Bu durum, hem tedavi güvenliğini artırmakta hem de tedavi süresinin uzamasını önleyebilmektedir (Liu ve ark., 2023b; Wong ve ark., 2023).

2.11.4. Klinik Verimlilik Katkıları

AI destekli tele-ortodonti uygulamaları, klinik verimlilik açısından önemli avantajlar sunmaktadır. Rutin kontrol randevularının bir kısmının uzaktan yürütülebilmesi, klinik yoğunluğu azaltmakta ve klinisyenlerin daha karmaşık vakalara odaklanmasını sağlamaktadır (American Dental Association, 2023).

Ayrıca bu sistemler, klinik süreçlerin daha iyi dokümente edilmesine ve veri temelli kalite kontrol mekanizmalarının geliştirilmesine olanak tanımaktadır. Çok merkezli klinik ağlarda, standartlaştırılmış uzaktan takip protokolleri sayesinde hasta yönetimi daha tutarlı hâle gelebilmektedir (European Orthodontic Society, 2024).

2.11.5. Uzaktan Takibin Sınırları

Tele-ortodonti ve AI entegrasyonunun çeşitli sınırlamaları bulunmaktadır. Uzaktan elde edilen görüntülerin kalitesi, hasta iş birliği ve teknik altyapı eksiklikleri, değerlendirme doğruluğunu olumsuz etkileyebilir. Ayrıca palpasyon, fonksiyonel analiz ve

ayrıntılı klinik muayene gerektiren durumlarda uzaktan takip yetersiz kalmaktadır (Cabitza ve ark., 2017; Topol, 2019).

Hukuki ve etik açıdan bakıldığında, uzaktan yapılan değerlendirmelerde sorumluluk paylaşımı net biçimde tanımlanmalıdır. AI tarafından üretilen analizlerin klinisyen tarafından onaylanması, hasta güvenliği ve hukuki sorumluluk açısından zorunlu kabul edilmektedir (European Commission, 2019).

Sonuç olarak tele-ortodonti, AI desteğiyle önemli bir potansiyele sahip olmakla birlikte; klinik pratiğin tamamlayıcı bir unsur olarak konumlandırılmalı ve yüz yüze muayenenin yerini tamamen alacak şekilde kullanılmamalıdır.

2.12. Ortodontide Yapay Zekânın Etik ve Hukuki

Boyutları

Ortodontide AI uygulamalarının klinik kullanıma entegrasyonu, yalnızca teknik doğruluk ve klinik fayda ile sınırlı değildir. Bu sistemler; tanı, tedavi planlaması ve hasta takibi gibi kritik karar süreçlerine doğrudan etki ettiğinden, etik ve hukuki boyutları da ayrıntılı biçimde ele alınmalıdır. AI destekli sistemlerin yanlış veya denetimsiz kullanımı, hasta güvenliği, mesleki sorumluluk ve sağlık hizmetlerinde adalet açısından ciddi riskler doğurabilir (European Commission, 2019; Schwendicke ve ark., 2020).

Güncel literatürde, AI'nın sağlık alanında “yardımcı karar destek aracı” olarak konumlandırılması gerektiği; klinik kararların nihai sorumluluğunun her zaman hekimde kalması gerektiği açıkça vurgulanmaktadır (Cabitza ve ark., 2017; Topol, 2019; American

Dental Association, 2023; World Health Organization, 2021; European Commission, 2019).

2.12.1. Yapay Zekâ Etiği

AI etiği, AI sistemlerinin insan onuruna, özerkliğine ve adalet ilkesine uygun biçimde geliştirilmesini ve kullanılmasını hedefleyen ilke ve yaklaşımlar bütünüdür. Sağlık alanında bu etik çerçeve, hasta güvenliği, şeffaflık, hesap verebilirlik ve zarar vermeme (non-maleficence) ilkeleri etrafında şekillenmektedir (European Commission, 2019).

Ortodontide AI etiği açısından temel sorunlardan biri, algoritmaların nasıl karar verdiğinin klinisyen ve hasta tarafından anlaşılabilir olmamasıdır. “Kara kutu” olarak tanımlanan bu durum, özellikle yüksek riskli tedavi kararlarında etik açıdan kabul edilebilir değildir. Bu nedenle açıklanabilir AI (XAI) yaklaşımları, etik kullanımın temel bileşenlerinden biri olarak değerlendirilmektedir (IEEE Global Initiative, 2020).

2.12.2. Automation Bias

Automation bias, klinisyenlerin AI sistemleri tarafından üretilen önerilere aşırı güven duyması ve bu önerileri yeterince sorgulamadan kabul etmesi durumunu ifade eder. Ortodontide otomasyon yanlılığı, yanlış tanı, uygunsuz tedavi planlaması ve hasta güvenliğinin tehlikeye girmesi gibi ciddi sonuçlara yol açabilir (Cabitza ve ark., 2017; Topol, 2019).

Literatürde, özellikle deneyim düzeyi düşük klinisyenlerin AI önerilerine daha fazla bağımlılık gösterebildiği bildirilmiştir. Bu

durum, AI'nın eğitsel bir destek aracı olarak kullanılmasını değerli kılmakla birlikte; bağımsız karar verici olarak konumlandırılmasının etik açıdan sakıncalı olduğunu ortaya koymaktadır (Topol, 2019).

Automation bias riskini azaltmak için:

- AI çıktılarının mutlaka klinisyen tarafından doğrulanması,
- sistemlerin sınırlamalarının açık biçimde belirtilmesi,
- klinisyenlerin AI okuryazarlığının artırılması

önerilmektedir (European Orthodontic Society, 2024).

2.12.3. Tıbbi Cihaz Regülasyonları

Ortodontide kullanılan AI tabanlı yazılımlar, birçok ülkede “tıbbi cihaz” kapsamında değerlendirilmektedir. Avrupa Birliği’nde CE işareti, Amerika Birleşik Devletleri’nde ise FDA onayı, bu tür yazılımların klinik kullanıma sunulabilmesi için temel gereklilikler arasında yer almaktadır (American Dental Association, 2023).

Bu regülasyonlar; yazılımın güvenliğini, performansını ve klinik geçerliliğini değerlendirmeyi amaçlamaktadır. Ancak AI sistemlerinin sürekli öğrenen ve güncellenen yapıları, mevcut regülasyon çerçevelerinin yeterliliğini tartışmalı hâle getirmiştir. Bu nedenle dinamik ve adaptif AI sistemleri için yeni düzenleyici yaklaşımlara ihtiyaç duyulmaktadır (European Commission, 2019; European Union, 2024).

2.12.4. Sorumluluk Paylaşımı

AI destekli sistemlerin kullanımıyla birlikte ortaya çıkan en önemli hukuki sorulardan biri, olası bir hata durumunda sorumluluğun

kime ait olacağıdır. Ortodontik uygulamalarda, AI tarafından önerilen bir planın uygulanması sonucu oluşabilecek olumsuzluklarda; yazılım geliştiricisi, klinik kurum ve hekim arasındaki sorumluluk paylaşımı net biçimde tanımlanmalıdır (Schwendicke ve ark., 2020).

Mevcut hukuki yaklaşımlar, AI'nın bağımsız bir özne olarak değil; hekimin kullandığı bir araç olarak değerlendirilmesi gerektiğini kabul etmektedir. Bu bağlamda, nihai klinik kararın sorumluluğu her zaman hekime aittir. AI çıktılarının otomatik olarak uygulanması, hukuki açıdan kabul edilebilir bir yaklaşım değildir (Cabitza ve ark., 2017; Topol, 2019).

2.12.5. Trustworthy AI İlkeleri

“Trustworthy AI” kavramı, AI sistemlerinin hem teknik hem de etik açıdan güvenilir olmasını ifade eder. Avrupa Komisyonu tarafından tanımlanan bu çerçeve, AI sistemlerinin aşağıdaki temel ilkeleri sağlamasını önermektedir (European Commission, 2019):

- İnsan gözetimi ve kontrolü,
- Teknik sağlamlık ve güvenlik,
- Veri gizliliği ve yönetim,
- Şeffaflık,
- Ayrımcılığın önlenmesi ve adalet,
- Toplumsal ve çevresel refah,
- Hesap verebilirlik.

Ortodontide geliştirilen ve kullanılan AI sistemlerinin bu ilkelere uygunluğu hem hasta güvenliği hem de mesleki etik açısından kritik öneme sahiptir. Trustworthy AI yaklaşımı, AI'nın klinik pratikte

sürdürülebilir ve kabul edilebilir biçimde kullanılmasının temelini oluşturmaktadır (European Orthodontic Society, 2024).

2.13. Veri Gizliliği ve Yasal Düzenlemeler

Ortodontide AI uygulamalarının temelini, büyük hacimli ve çoğunlukla kişisel sağlık verisi niteliği taşıyan veri setleri oluşturmaktadır. Radyografiler, dijital dental modeller, yüz fotoğrafları ve klinik kayıtlar; doğrudan veya dolaylı olarak hastanın kimliğini belirleyebilecek bilgiler içermektedir. Bu nedenle AI sistemlerinin geliştirilmesi ve klinik kullanımında veri gizliliği ve yasal düzenlemeler kritik öneme sahiptir (European Commission, 2019; Schwendicke ve ark., 2020).

Veri güvenliğine ilişkin ihlaller, yalnızca hukuki yaptırımlara değil; hasta güveninin zedelenmesine ve AI teknolojilerine karşı genel bir güvensizlik oluşmasına da yol açabilmektedir. Bu bağlamda ortodontide AI uygulamaları, yürürlükteki ulusal ve uluslararası veri koruma mevzuatlarına tam uyumlu biçimde tasarlanmalı ve kullanılmalıdır (American Dental Association, 2023).

2.13.1. KVKK ve Kişisel Sağlık Verileri

Türkiye’de kişisel sağlık verilerinin korunması, 6698 sayılı Kişisel Verilerin Korunması Kanunu (KVKK) kapsamında düzenlenmektedir. Ortodontik görüntüler ve klinik kayıtlar, KVKK’ya göre “özel nitelikli kişisel veri” olarak kabul edilmekte ve bu verilerin işlenmesi sıkı koşullara bağlanmaktadır (KVKK, 2016).

AI modellerinin eğitimi sırasında kullanılan veriler için:

- hastadan açık rıza alınması,

- verinin işleme amacının açıkça belirtilmesi,
- verinin yalnızca gerekli süre boyunca saklanması

zorunludur. Özellikle araştırma amaçlı veri kullanımlarında, klinik hizmet sunumundan ayrı bir açık rıza sürecinin yürütülmesi etik ve hukuki açıdan gereklidir (Schwendicke ve ark., 2020).

2.13.2. Anonimleştirme Stratejileri

AI geliştirme süreçlerinde veri gizliliğini sağlamanın en temel yöntemlerinden biri anonimleştirmedir. Anonimleştirme, kişisel verilerin kimliği belirli veya belirlenebilir bir gerçek kişiyle ilişkilendirilemeyecek hâle getirilmesini ifade eder (European Commission, 2019).

Ortodontik veri setlerinde anonimleştirme; hasta isimlerinin silinmesi, kimlik numaralarının kaldırılması ve meta verilerin temizlenmesi gibi işlemleri içerebilir. Ancak yüz fotoğrafları ve 3B yüz taramaları gibi verilerde tam anonimleştirmenin teknik olarak zor olduğu bilinmektedir. Bu tür veriler, literatürde “yeniden tanımlanabilir veri” (re-identifiable data) kapsamında değerlendirilmekte ve ek güvenlik önlemleri gerektirmektedir (IEEE Global Initiative, 2020).

Bu nedenle anonimleştirme, tek başına yeterli bir önlem olarak değil; veri güvenliği stratejilerinin bir bileşeni olarak ele alınmalıdır.

2.13.3. Veri Saklama Güvenliği

Ortodontik AI sistemlerinde veri saklama güvenliği, hem teknik hem de yönetsel önlemleri kapsar. Yetkisiz erişimlerin önlenmesi, veri bütünlüğünün korunması ve veri kaybının

engellenmesi temel hedefler arasında yer almaktadır (American Dental Association, 2023).

Bulut tabanlı AI çözümlerinin yaygınlaşmasıyla birlikte, verilerin hangi ülkede saklandığı ve hangi hukuki rejime tabi olduğu da önem kazanmıştır. Bulut servis sağlayıcılarının sağlık verilerine ilişkin güvenlik sertifikalarına sahip olması ve veri işleme sözleşmelerinin açık biçimde tanımlanması gerekmektedir (European Orthodontic Society, 2024).

Klinik düzeyde ise erişim yetkilendirmelerinin sınırlandırılması ve veri kayıtlarının düzenli olarak denetlenmesi, veri güvenliğinin sağlanmasında önemli rol oynamaktadır.

2.13.4. Uluslararası Veri Koruma Çerçevesi

Ortodontide AI uygulamalarının büyük bir bölümü, uluslararası yazılım ve donanım sağlayıcıları tarafından geliştirilmektedir. Bu durum, verilerin sınır ötesi aktarımı konusunu gündeme getirmektedir. Avrupa Birliği Genel Veri Koruma Tüzüğü (GDPR), kişisel sağlık verilerinin uluslararası aktarımına ilişkin katı kurallar getirmektedir (European Commission, 2019).

GDPR kapsamında, Avrupa Birliği dışına veri aktarımı yapılabilmesi için yeterli koruma düzeyinin sağlanması veya ek sözleşmesel önlemlerin alınması gerekmektedir. Ortodontik AI yazılımlarının GDPR uyumluluğu, özellikle çok uluslu klinik ağlarda ve araştırma projelerinde kritik bir gereklilik olarak öne çıkmaktadır (Schwendicke ve ark., 2020).

2.13.5. Klinik Yazılım Onay Süreçleri

AI tabanlı ortodontik yazılımlar, veri gizliliği ve güvenliği açısından yalnızca geliştirici firmaların beyanlarına dayanmamalıdır. Klinik kullanım öncesinde, bu yazılımların veri işleme süreçleri, güvenlik protokolleri ve yasal uyumluluğu bağımsız denetimlerden geçirilmelidir (American Dental Association, 2023).

CE işareti ve FDA onayı gibi regülasyon süreçleri, yazılımın teknik ve klinik güvenliğinin yanı sıra veri koruma ilkelerine uygunluğunu da değerlendirmektedir. Klinik kullanıcıların, kullandıkları AI yazılımlarının hangi veri güvenliği standartlarına tabi olduğunu bilmesi ve bu konuda bilgilendirilmiş olması mesleki sorumluluğun bir parçası olarak değerlendirilmektedir (European Orthodontic Society, 2024).

2.14. Model Validasyonu ve Klinik Güvenilirlik

Ortodontide AI tabanlı sistemlerin klinik kullanıma güvenle entegre edilebilmesi, geliştirilen modellerin geçerlilik (validity) ve güvenilirlik (reliability) kriterlerini sağlamasına bağlıdır. Yüksek doğruluk değerleri tek başına klinik kullanım için yeterli değildir; modellerin farklı hasta gruplarında, farklı cihazlarla ve değişen klinik koşullar altında tutarlı performans sergilemesi gerekmektedir (Bishop, 2019; Schwendicke ve ark., 2020).

Literatürde, ortodontide geliştirilen birçok AI modelinin araştırma aşamasında kaldığı ve klinik entegrasyon öncesinde yeterli validasyon sürecinden geçirilmediği bildirilmektedir. Bu durum, AI

uygulamalarına yönelik temkinli yaklaşımın temel nedenlerinden biridir (European Orthodontic Society, 2024).

2.14.1. İç Validasyon

İç validasyon, bir AI modelinin eğitildiği veri seti içerisindeki performansının değerlendirilmesini ifade eder. Bu süreçte model, eğitim verisinin farklı alt kümeleri kullanılarak test edilir ve performans ölçütleri hesaplanır. Cross-validation yöntemleri, iç validasyonun en yaygın kullanılan biçimlerindendir (Litjens ve ark., 2017). En sık kullanılan yöntemler arasında eğitim–test ayrımı, k-katlı cross-validation ve bootstrap teknikleri yer almaktadır (Hastie ve ark., 2009).

Ortodontik çalışmalarda iç validasyon, modelin veri setini ne ölçüde öğrendiğini ve overfitting riskini değerlendirmek açısından önemlidir. Ancak yalnızca iç validasyon sonuçlarına dayanarak klinik çıkarımlar yapmak, model performansının olduğundan daha iyi algılanmasına yol açabilir (Cabitza ve ark., 2017; Topol, 2019). Bu durum, özellikle küçük ve homojen veri setlerinde belirgindir (Poldrack ve ark., 2020).

Bu nedenle iç validasyon, gerekli ancak tek başına yeterli olmayan bir adım olarak kabul edilmektedir.

2.14.2. Dış Validasyon

Dış validasyon, AI modelinin eğitim sürecinde hiç kullanılmamış, farklı merkezlerden veya farklı cihazlardan elde edilmiş veri setleri üzerinde test edilmesini ifade eder. Klinik

güvenilirliğin değerlendirilmesinde en kritik aşama dış validasyondur (Bishop, 2019; Beam & Kohane, 2018).

Ortodontide yapılan birçok AI çalışmasının, yalnızca tek merkezli veri setleriyle geliştirildiği ve dış validasyon içermediği bildirilmektedir. Bu durum, modellerin farklı popülasyonlarda performans kaybı yaşamasına neden olabilmektedir (Liu ve ark., 2023a; 2023b; Koletsi ve ark., 2021; Collins ve ark., 2024; Kelly ve ark., 2019).

European Orthodontic Society (2024), klinik kullanıma aday AI sistemlerinin mutlaka çok merkezli ve farklı popülasyonları içeren dış validasyon çalışmalarından geçirilmesini önermektedir.

2.14.3. Veri Kaynağına Bağlı Performans

AI modellerinin performansı, büyük ölçüde kullanılan veri kaynağının niteliğine bağlıdır. Görüntüleme cihazları arasındaki teknik farklılıklar, çözünürlük değişimleri ve çekim protokollerindeki varyasyonlar, model çıktılarında anlamlı farklılıklara yol açabilmektedir (Gokdeniz & Kamburoğlu, 2022; Laitenberger ve ark., 2023; Hung ve ark., 2023; Dipalma ve ark., 2023).

Ortodontik görüntüleme alanında geliştirilen birçok model, belirli bir cihaz veya yazılım ekosistemi ile sınırlı veri setleri kullanılarak eğitilmiştir. Bu durum, farklı klinik ortamlarda genellenebilirliği sınırlayan önemli bir faktördür (Litjens ve ark., 2017).

Bu nedenle klinik güvenilirlik değerlendirilirken, modelin hangi veri kaynaklarıyla eğitildiği ve hangi koşullarda test edildiği açık biçimde raporlanmalıdır.

2.14.4. Genellenebilirlik Problemleri

Genellenebilirlik, bir AI modelinin eğitim verisi dışında kalan hasta gruplarında da benzer performans sergileyebilme yeteneğini ifade eder. Ortodontik veri setlerinde yaş, cinsiyet, etnik köken ve maloklüzyon dağılımındaki dengesizlikler, genellenebilirliği olumsuz etkileyebilmektedir (Cabitza ve ark., 2017; Topol, 2019).

Özellikle pediatrik ve erişkin hasta grupları arasında biyolojik yanıt farklılıkları bulunması, tek tip modellerin tüm hasta popülasyonlarında güvenle kullanılmasını zorlaştırmaktadır. Bu nedenle literatürde, alt grup analizleri ve popülasyon temelli performans raporlaması önerilmektedir (Poldrack ve ark., 2020; Koletsis ve ark., 2021).

Genellenebilirlik problemi, yalnızca teknik bir sınırlama değil; aynı zamanda etik bir sorundur. Belirli hasta gruplarında sistematik olarak düşük performans gösteren AI sistemleri, sağlık hizmetlerinde eşitsizlik riskini artırabilir (European Commission, 2019).

2.14.5. Klinik Kabul Kriterleri

Bir AI modelinin klinik kabul görebilmesi için aşağıdaki temel kriterleri karşılaması gerekmektedir:

- yeterli iç ve dış validasyon sonuçları,
- klinik olarak anlamlı performans ölçütleri,
- açıklanabilir ve şeffaf karar mekanizmaları,

- hasta güvenliğini önceleyen risk yönetimi,
- regülasyonlara ve etik ilkelere uyum.

Ortodontide AI uygulamalarının klinik kabulü, yalnızca akademik yayınlarla değil; uzun dönemli klinik performans ve kullanıcı deneyimleriyle de şekillenmektedir. Bu nedenle model validasyonu, tek seferlik bir süreç değil; klinik kullanım boyunca devam eden dinamik bir değerlendirme olarak ele alınmalıdır (American Dental Association, 2023; European Orthodontic Society, 2024).

Sonuç olarak model validasyonu ve klinik güvenilirlik, ortodontide AI'nın sürdürülebilir ve güvenli biçimde kullanılmasının temelini oluşturmaktadır.

2.15. AI + VR Simülasyonları

Sanal gerçeklik (*Virtual Reality*, VR), kullanıcıyı bilgisayar tarafından oluşturulmuş üç boyutlu bir ortama dâhil ederek etkileşimli deneyimler sunan bir teknolojidir. AI ile birlikte kullanıldığında VR, ortodontide hem klinik planlama hem de eğitim amaçlı olarak yeni ve güçlü bir simülasyon altyapısı ortaya koymaktadır (Radianti ve ark., 2020; Jensen & Konradsen, 2018). AI + VR entegrasyonu, statik dijital modellerin ötesine geçerek dinamik, hasta-özü ve gerçek zamanlı geri bildirim sunabilen sistemlerin geliştirilmesine olanak tanımaktadır (Topol, 2019; Liu ve ark., 2023b; Wong ve ark., 2023).

Ortodontide VR simülasyonlarının temel amacı, klinik karar süreçlerini desteklemek, karmaşık biyomekanik ilişkileri görselleştirmek ve riskli girişimleri hasta üzerinde uygulanmadan

önce güvenli bir sanal ortamda değerlendirmektir. AI, bu simülasyonların gerçekçi ve öngörülebilir olmasını sağlayan temel bileşen olarak öne çıkmaktadır (Kyaw ve ark., 2019; Moro ve ark., 2017; Pottle, 2019).

2.15.1. Ortodontik Tedavi Simülasyonlarında VR'nin Rolü

VR tabanlı ortodontik simülasyonlar, diş hareketlerinin, apacey etkilerinin ve çene ilişkilerinin üç boyutlu ve zaman bağımlı olarak görselleştirilmesini mümkün kılar. Geleneksel dijital set-up'lar genellikle statik aşamalar sunarken, VR ortamları diş hareketlerinin dinamik bir süreç olarak izlenmesine olanak tanımaktadır (Liu ve ark., 2023b; Tomášik ve ark., 2024).

Bu simülasyonlarda AI, geçmiş hasta verilerinden öğrenerek olası tedavi senaryolarını optimize edebilmekte ve farklı tedavi seçeneklerinin sonuçlarını karşılaştırmalı olarak sunabilmektedir. Böylece klinisyen, tedaviye başlamadan önce olası riskleri ve sınırları daha net biçimde değerlendirebilmektedir (Liu ve ark., 2023b; Wong ve ark., 2023).

2.15.2. AI Destekli Biyomekanik Simülasyonlar

AI + VR entegrasyonunun en önemli kullanım alanlarından biri, biyomekanik simülasyonlardır. AI, FEA temelli biyomekanik modellerden elde edilen büyük veri kümelerini kullanarak kuvvet-hareket ilişkilerini öğrenebilmekte ve VR ortamında gerçek zamanlı simülasyonlar üretebilmektedir (Wu ve ark., 2018; Yang ve ark., 2025; Wu ve ark., 2022).

Bu tür simülasyonlar sayesinde:

- farklı kuvvet uygulama senaryoları karşılaştırılabilir,
- kök rezorpsiyonu riski taşıyan bölgeler görselleştirilebilir,
- aparey tasarımlarının biyomekanik etkileri önceden değerlendirilebilir.

VR ortamında sunulan bu görselleştirmeler, özellikle karmaşık vakalarda klinik karar sürecini destekleyen güçlü araçlar olarak değerlendirilmektedir (Wu ve ark., 2018).

2.15.3. Hasta-Özgü Dijital İkiz (Digital Twin) Yaklaşımı

AI + VR entegrasyonunun en ileri uygulamalarından biri, “dijital ikiz” kavramıdır. Dijital ikiz, hastanın anatomik, biyomekanik ve klinik özelliklerini yansıtan sanal bir temsil olarak tanımlanmaktadır. AI, hastaya ait görüntüleme ve klinik verileri kullanarak bu sanal modeli sürekli güncelleyebilmekte; VR ise bu modeli etkileşimli bir ortamda sunmaktadır (Topol, 2019).

Ortodontide dijital ikiz yaklaşımı, farklı tedavi senaryolarının aynı hasta modeli üzerinde test edilmesine olanak tanımaktadır. Bu yaklaşım, özellikle uzun süreli tedavilerde ve ortognatik cerrahi ile kombine vakalarda büyük potansiyel taşımaktadır. Ancak mevcut uygulamaların büyük bölümü hâlen deneysel aşamadadır ve klinik geçerliliği sınırlıdır (European Orthodontic Society, 2024).

2.15.4. Klinik Karar Destek ve Hasta İletişimi

VR tabanlı simülasyonlar, yalnızca klinisyen için değil; hasta iletişimi açısından da önemli avantajlar sunmaktadır. AI destekli VR

uygulamaları, hastalara planlanan tedavi sürecini üç boyutlu ve anlaşılır bir şekilde sunabilmektedir. Bu durum, hasta bilgilendirme sürecini güçlendirmekte ve tedaviye uyumu artırabilmektedir (Liu ve ark., 2023b; Tomášik ve ark., 2024).

Ancak literatürde, VR simülasyonlarının sunduğu görselleştirmelerin “kesin sonuç” algısı yaratmaması gerektiği vurgulanmaktadır. AI tarafından üretilen simülasyonlar, olasılıksal tahminlerdir ve biyolojik yanıtların bireysel farklılık gösterebileceği hastaya açıkça ifade edilmelidir (Cabitza ve ark., 2017; Topol, 2019).

2.15.5. Mevcut Sınırlamalar ve Gelecek Perspektifi

AI + VR simülasyonlarının ortodontide yaygın klinik kullanımı, çeşitli teknik ve etik sınırlamalarla karşı karşıyadır. Yüksek donanım maliyetleri, veri entegrasyon zorlukları ve standartlaşma eksikliği, bu sistemlerin rutin klinik pratiğe girmesini zorlaştırmaktadır (European Commission, 2019).

Ayrıca simülasyonların doğruluğu, kullanılan AI modellerinin validasyon düzeyiyle doğrudan ilişkilidir. Yetersiz valide edilmiş modellerle oluşturulan VR simülasyonları, klinik açıdan yanıltıcı sonuçlar doğurabilir. Bu nedenle AI + VR sistemlerinin, karar verici değil; ileri düzey karar destek ve eğitim aracı olarak konumlandırılması gerektiği görüşü literatürde ağırlık kazanmaktadır (European Orthodontic Society, 2024).

2.16. AI Destekli Eğitim Yazılımları

AI destekli eğitim yazılımları, ortodonti eğitiminde geleneksel öğretim yöntemlerini tamamlayan ve bireyselleştirilmiş öğrenme

deneyimleri sunan yenilikçi araçlar olarak öne çıkmaktadır. Dijital görüntüleme, simülasyon ve veri analitiği ile bütünleşen bu yazılımlar; öğrenci, asistan ve klinisyenlerin bilgi düzeylerini objektif ölçütlerle değerlendirmeyi ve geliştirmeyi amaçlamaktadır (Topol, 2019; Liu ve ark., 2023b; Wong ve ark., 2023).

Ortodontide AI destekli eğitim sistemlerinin temel hedefi, yalnızca bilgi aktarımı değil; klinik karar verme becerilerinin geliştirilmesi, hata farkındalığının artırılması ve standardize edilmiş eğitim çıktılarının sağlanmasıdır (Masters, 2020; Claman & Sezgin, 2024). Bu yönüyle AI, eğitim sürecinde pasif bir içerik sunucusu olmaktan ziyade aktif bir öğrenme ortağı olarak konumlanmaktadır (Wartman & Combs, 2018; Chan ve ark., 2019).

2.16.1 Kişiselleştirilmiş Öğrenme ve Adaptif Eğitim

AI destekli eğitim yazılımları, kullanıcıların bilgi düzeyini, öğrenme hızını ve hata örüntülerini analiz ederek kişiselleştirilmiş eğitim içerikleri sunabilmektedir. Adaptif öğrenme sistemleri, öğrencinin güçlü ve zayıf yönlerine göre eğitim materyallerini dinamik biçimde düzenlemektedir (Bishop, 2019).

Ortodonti eğitiminde bu yaklaşım; sefalometrik analiz, dijital model değerlendirmesi ve tedavi planlaması gibi konularda bireysel öğrenme boşluklarının daha erken fark edilmesini sağlamaktadır. Böylece eğitim süreci, “herkese aynı içerik” anlayışından uzaklaşarak yetkinlik temelli bir yapıya dönüşmektedir (Liu ve ark., 2023a; 2023b).

2.16.2. Klinik Senaryo ve Vaka Tabanlı Eğitim

AI destekli eğitim yazılımlarının önemli bir bileşeni, vaka tabanlı öğrenme modülleridir. Bu sistemler, gerçek klinik vakalardan elde edilen anonimleştirilmiş verilerle oluşturulan senaryolar üzerinden kullanıcıların tanı ve tedavi planlama becerilerini test etmektedir (Liu ve ark., 2023b; Tomášik ve ark., 2024).

AI, kullanıcının verdiği kararları analiz ederek alternatif yaklaşımlar sunabilmekte ve olası klinik sonuçları karşılaştırmalı biçimde gösterebilmektedir. Bu yaklaşım, özellikle ortodonti asistanlarının klinik deneyim kazanmadan önce güvenli bir ortamda hata yapabilmelerine olanak tanımaktadır (Liu ve ark., 2023b; Wong ve ark., 2023).

2.16.3. Otomatik Değerlendirme ve Geri Bildirim

Sistemleri

Geleneksel eğitim yöntemlerinde değerlendirme çoğunlukla subjektif gözlemlere dayanırken, AI destekli eğitim yazılımları objektif ve tekrarlanabilir ölçütler sunmaktadır. Otomatik değerlendirme sistemleri; landmark yerleştirme doğruluğu, ölçüm hataları ve tedavi planlama tutarlılığı gibi parametreleri nicel olarak analiz edebilmektedir (Shin ve ark., 2021).

Bu sistemler, anlık geri bildirim sağlayarak öğrenme sürecini hızlandırmakta ve hataların kalıcı hâle gelmesini önlemektedir. Literatürde, erken ve yapılandırılmış geri bildirimin klinik beceri kazanımını anlamlı ölçüde artırdığı bildirilmektedir (Topol, 2019).

2.16.4. Standartlaştırılmış Eğitim ve Yetkinlik Ölçümü

AI destekli eğitim yazılımları, ortodonti eğitiminde standartlaştırılmış yetkinlik ölçümü açısından önemli bir potansiyel taşımaktadır. Farklı eğitim kurumları ve klinik ortamlar arasında gözlenen eğitim farklılıkları, AI tabanlı objektif değerlendirme araçlarıyla azaltılabilir (European Orthodontic Society, 2024).

Bu sistemler, belirli eğitim hedeflerine ulaşma düzeyini izleyerek kullanıcıların klinik yeterliliklerini belgeleyebilir. Ancak literatürde, bu tür ölçümlerin yüz yüze mentorluk ve klinik değerlendirmelerin yerini almaması; aksine onları desteklemesi gerektiği vurgulanmaktadır (American Dental Association, 2023).

2.16.5. Etik ve Eğitsel Sınırlamalar

AI destekli eğitim yazılımlarının kullanımı, bazı etik ve eğitsel sınırlamaları da beraberinde getirmektedir. Algoritmaların hangi kriterlere göre değerlendirme yaptığı ve geri bildirim ürettiği şeffaf biçimde tanımlanmalıdır. Aksi takdirde, öğrenenler üzerinde gereksiz bir “algoritmik otorite” algısı oluşabilir (Cabitza ve ark., 2017; Topol, 2019).

Ayrıca AI destekli eğitim sistemleri, klinik deneyimin ve hasta etkileşiminin yerini alamaz. Ortodonti eğitimi, teknik bilgi kadar iletişim, empati ve klinik muhakeme becerilerini de içermektedir. Bu nedenle AI tabanlı eğitim yazılımları, tamamlayıcı eğitim araçları olarak konumlandırılmalı ve insan eğitmenlerin rehberliğiyle birlikte kullanılmalıdır (European Commission, 2019).

SONUÇ VE GELECEK PERSPEKTİFLERİ

AI, ortodontide tanı, tedavi planlaması, tedavi takibi ve eğitim süreçlerinde önemli bir dönüşüm potansiyeli sunmaktadır. Otomatik sefalometrik analizler, dijital dental model değerlendirmeleri, tedavi süresi ve sonuç tahminleri gibi uygulamalar; klinik iş akışlarını daha verimli, standart ve veri temelli hâle getirmektedir. Bu teknolojiler, özellikle zaman yönetimi, ölçüm tekrarlanabilirliği ve klinik karar destek açısından ortodontik pratiğe anlamlı katkılar sağlamaktadır (Schwendicke ve ark., 2020; Koletsi ve ark., 2021).

Bu kitap boyunca ele alınan çalışmalar, AI'nın ortodontideki rolünün hiçbir zaman klinisyenin yerini almak olmadığını; aksine klinisyenin deneyimini destekleyen ve karar verme sürecini güçlendiren bir araç olarak konumlandırılması gerektiğini açık biçimde ortaya koymaktadır. AI tabanlı sistemlerin sunduğu çıktılar, biyolojik yanıtların bireysel farklılıklar gösterdiği gerçeği göz önünde bulundurularak klinik uzmanlıkla birlikte değerlendirilmelidir (Cabitza ve ark., 2017; Topol, 2019).

Ortodontide AI uygulamalarının mevcut durumu incelendiğinde, literatürde yer alan çalışmaların büyük bölümünün araştırma ve prototip aşamasında olduğu görülmektedir. Klinik rutinde yaygın kullanım, yalnızca yüksek doğruluk değerleriyle değil; aynı zamanda model validasyonu, genellenebilirlik, açıklanabilirlik ve hasta güvenliği kriterlerinin karşılanmasıyla mümkün olacaktır (European Orthodontic Society, 2024).

Geleceğe yönelik olarak, ortodontide AI'nın gelişiminin birkaç temel eksen etrafında şekilleneceği öngörülmektedir. Bunlardan ilki,

multimodal veri entegrasyonudur. Görüntü verileri, klinik ölçümler, biyomekanik simülasyonlar ve hasta davranışlarının birlikte değerlendirildiği AI sistemleri, daha hassas ve kişiselleştirilmiş tedavi yaklaşımlarının geliştirilmesine olanak tanıyacaktır (Topol, 2019).

İkinci önemli gelişim alanı, **kışıselleştirilmiş ve adaptif ortodonti yaklaşımlarıdır.** AI destekli modeller, hastaya özgü biyolojik ve anatomik farklılıkları daha iyi temsil edebildikçe; tedavi planları “ortalama hasta” kavramından uzaklaşarak bireysel risk ve yanıt profillerine göre şekillenecektir. Bu durum, tedavi etkinliğinin artmasına ve yan etkilerin azaltılmasına katkı sağlayabilir (Liu ve ark., 2023b; Wong ve ark., 2023).

Üçüncü olarak, **AI + VR simülasyonları ve dijital ikiz yaklaşımları** hem klinik planlama hem de eğitim alanında önemli bir potansiyel sunmaktadır. Hastaya özgü sanal modeller üzerinde farklı tedavi senaryolarının test edilebilmesi, klinik karar sürecini daha öngörülebilir ve güvenli hâle getirebilir. Ancak bu teknolojilerin klinik rutine entegrasyonu için uzun dönemli klinik çalışmalar ve güçlü validasyon süreçleri gereklidir (European Commission, 2019).

Bununla birlikte AI'nın ortodontide yaygın kullanımının önündeki en önemli sınırlamalar; veri gizliliği, etik sorumluluklar ve regülasyon eksiklikleridir. Kişisel sağlık verilerinin korunması, algoritmik önyargıların önlenmesi ve automation bias riskinin yönetilmesi, gelecekteki AI uygulamalarının güvenilirliği açısından kritik öneme sahiptir. Bu bağlamda Trustworthy AI ilkeleri, ortodontik AI sistemlerinin geliştirilmesi ve kullanımında temel

referans çerçevesi olarak benimsenmelidir (European Commission, 2019).

Sonuç olarak AI, ortodontide güçlü bir dönüşüm aracı olmakla birlikte; bilimsel kanıt, etik sorumluluk ve klinik uzmanlık ile dengeli biçimde kullanıldığında gerçek potansiyeline ulaşacaktır. Bu kitap, ortodontide AI uygulamalarını teorik temelleri, klinik yansımaları ve gelecek perspektifleriyle bütüncül biçimde ele alarak; klinisyenler, araştırmacılar ve öğrenciler için yol gösterici bir başvuru kaynağı sunmayı amaçlamaktadır.

KAYNAKÇA

- American Dental Association. (2023). Policy on artificial intelligence in dentistry. ADA.
- Beam, A. L., & Kohane, I. S. (2018). Big Data and Machine Learning in Health Care. *JAMA*, 319(13), 1317–1318.
- Bichu, Y. M., Hansa, I., Bichu, A. Y., Premjani, P., Flores-Mir, C., & Vaid, N. R. (2021). Applications of artificial intelligence and machine learning in orthodontics: a scoping review. *Progress in orthodontics*, 22(1), 18.
- Bichu, Y.M., Zou, B., Chaudhari, P.K., Adel, S.M., Vaid, N. (2025). Artificial Intelligence Applications in Orthodontics. In: Schwendicke, F., Chaudhari, P.K., Dhingra, K., Uribe, S.E., Hamdan, M. (eds) *Artificial Intelligence for Oral Health Care*. Springer
- Bishop, C. M. (2019). *Pattern recognition and machine learning* (2nd ed.). Springer.
- Cabitza, F., Rasoini, R., & Gensini, G. F. (2017). Unintended Consequences of Machine Learning in Medicine. *JAMA*, 318(6), 517–518.
- Chan, K. S., & Zary, N. (2019). Applications and Challenges of Implementing Artificial Intelligence in Medical Education: Integrative Review. *JMIR medical education*, 5(1), e13930.
- Claman, D., & Sezgin, E. (2024). Artificial Intelligence in Dental Education: Opportunities and Challenges of Large Language Models and Multimodal Foundation Models. *JMIR medical education*, 10, e52346.

- Collins, G. S., Moons, K. G. M., Dhiman, P., et al. (2024). TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ (Clinical research ed.)*, 385, e078378.
- Dipalma, G., Inchingolo, A. D., Inchingolo, A. M., Piras, F., Carpentiere, V., Garofoli, G., Azzollini, D., Campanelli, M., Paduanelli, G., Palermo, A., & Inchingolo, F. (2023). Artificial Intelligence and Its Clinical Applications in Orthodontics: A Systematic Review. *Diagnostics (Basel, Switzerland)*, 13(24), 3677.
- European Commission. (2019). Ethics guidelines for trustworthy artificial intelligence. EU.
- European Orthodontic Society. (2024). Artificial intelligence in orthodontics: Clinical recommendations. *European Journal of Orthodontics*.
- European Union. (2024). Artificial Intelligence Act. Official Journal of the EU.
- Flügge, T., Vinayahalingam, S., van Nistelrooij, N., Kellner, S., Xi, T., van Ginneken, B., Bergé, S., Heiland, M., Kernen, F., Ludwig, U., & Odaka, K. (2025). Automated tooth segmentation in magnetic resonance scans using deep learning- A pilot study. *Dento maxillo facial radiology*, 54(1), 12–18.
- Gao, F., & Tang, Y. (2025). Multimodal deep learning for cephalometric landmark detection and treatment prediction. *Scientific reports*, 15(1), 25205.

- Gokdeniz, S. T., & Kamburoğlu, K. (2022). Artificial intelligence in dentomaxillofacial radiology. *World journal of radiology*, 14(3), 55–59.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Graber, L. W., Vanarsdall, R. L., & Vig, K. W. L. (2016). *Orthodontics: Current principles and techniques* (6th ed.). Elsevier.
- Gracea, R. S., Winderickx, N., Vanheers, M., Hendrickx, J., Preda, F., Shujaat, S., Cadenas de Llano-Pérula, M., & Jacobs, R. (2025). Artificial intelligence for orthodontic diagnosis and treatment planning: A scoping review. *Journal of dentistry*, 152, 105442.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning* (2nd ed.). Springer.
- Hong, M., Kim, I., Cho, J. H., et al. (2022). Accuracy of artificial intelligence-assisted landmark identification in serial lateral cephalograms of Class III patients who underwent orthodontic treatment and two-jaw orthognathic surgery. *Korean journal of orthodontics*, 52(4), 287–297.
- Hung, K. F., Yeung, A. W. K., Bornstein, M. M., & Schwendicke, F. (2023). Personalized dental medicine, artificial intelligence, and their relevance for dentomaxillofacial imaging. *Dentomaxillofacial Radiology*, 52(1), 20220335.
- Hwang, H. W., Park, J. H., Moon, J. H., Yu, Y., Kim, H., Her, S. B., & Srinivasan, G. (2020). Automated identification of cephalometric landmarks: Part 2—Performance evaluation using

- a convolutional neural network. *Korean Journal of Orthodontics*, 50(1), 20–29.
- Jensen, L., & Konradsen, F. (2018). A review of the use of virtual reality head-mounted displays in education and training. *Education and Information Technologies*, 23(4), 1515–1529.
- Jeong, S. H., Yun, J. P., Yeom, H. G., Kim, H. K., & Kim, B. C. (2021). Deep-Learning-Based Detection of Cranio-Spinal Differences between Skeletal Classification Using Cephalometric Radiography. *Diagnostics (Basel, Switzerland)*, 11(4), 591.
- Kelly, J. T., Campbell, K. L., Gong, E., & Scuffham, P. (2019). The impact of telehealth on patient satisfaction and clinical outcomes. *Journal of Medical Internet Research*, 21(8), e13150.
- Koletsis, D., Iliadi, A., & Eliades, T. (2021). Predictability of rotational tooth movement with orthodontic aligners comparing software-based and achieved data: A systematic review and meta-analysis of observational studies. *Journal of orthodontics*, 48(3), 277–287.
- Köktürk, B., Pamukçu, H., & Gözüaçık, Ö. (2024). Evaluation of different machine learning algorithms for extraction decision in orthodontic treatment. *Orthodontics & craniofacial research*, 27 Suppl 2(Suppl 2), 13–24.
- Kyaw, B. M., Saxena, N., Posadzki, P., et al. (2019). Virtual Reality for Health Professions Education: Systematic Review and Meta-Analysis by the Digital Health Education Collaboration. *Journal of medical Internet research*, 21(1), e12959.


- Laitenberger, F., Güller, A., & Stellzig-Eisenhauer, A. (2023). Clinical accuracy of artificial intelligence–based cephalometric landmark detection. *Orthodontics & Craniofacial Research*, 26(2), 214–223.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60–88.
- Liu, J., Li, Y., Zhang, Y., & Chen, Y. (2023a). Applications of artificial intelligence in orthodontics: A scoping review. *American Journal of Orthodontics and Dentofacial Orthopedics*, 164(2), 185–197. <https://doi.org/10.1016/j.ajodo.2022.11.015>
- Liu, J., Zhang, C., & Shan, Z. (2023b). Application of Artificial Intelligence in Orthodontics: Current State and Future Perspectives. *Healthcare (Basel, Switzerland)*, 11(20), 2760.
- Lo Giudice, A., Ronsivalle, V., Venezia, P., Ragusa, R., Palazzo, G., Leonardi, R., & Lazzara, A. (2022). Teleorthodontics: Where Are We Going? From Skepticism to the Clinical Applications of a New Medical Communication and Management System. *International journal of dentistry*, 2022, 7301576.
- Mason, T., Kelly, K. M., Eckert, G., Dean, J. A., Dundar, M. M., & Turkkahraman, H. (2023). A machine learning model for orthodontic extraction/non-extraction decision in a racially and ethnically diverse patient population. *International orthodontics*, 21(3), 100759.

- Masters K. (2020). Artificial Intelligence developments in medical education: a conceptual and practical framework. *MedEdPublish* (2016), 9, 239.
- Moro, C., Štromberga, Z., Raikos, A., & Stirling, A. (2017). The effectiveness of virtual and augmented reality in health sciences and medical anatomy. *Anatomical sciences education*, 10(6), 549–559.
- Nan, L., Tang, M., Liang, B., Mo, S., Kang, N., Song, S., Zhang, X., & Zeng, X. (2023). Automated Sagittal Skeletal Classification of Children Based on Deep Learning. *Diagnostics* (Basel, Switzerland), 13(10), 1719.
- Park, J. H., Hwang, H. W., Moon, J. H., Yu, Y., Kim, H., Her, S. B., Srinivasan, G., Aljanabi, M. N. A., Donatelli, R. E., & Lee, S. J. (2019). Automated identification of cephalometric landmarks: Part 1-Comparisons between the latest deep-learning methods YOLOV3 and SSD. *The Angle orthodontist*, 89(6), 903–909.
- Park, W., Kim, Y. J., Lee, J. H., & Kim, T. W. (2021). Deep learning–based orthodontic diagnosis using facial photographs. *Diagnostics*, 11(9), 1702.
- Poldrack, R. A., Huckins, G., & Varoquaux, G. (2020). Establishment of Best Practices for Evidence for Prediction: A Review. *JAMA psychiatry*, 77(5), 534–540.
- Polizzi, A., Boato, M., Serra, S., D'Antò, V., & Leonardi, R. (2025). Applications of artificial intelligence in orthodontics: a bibliometric and visual analysis. *Clinical oral investigations*, 29(1), 65.

- Pottle, J. (2019) Virtual Reality and the Transformation of Medical Education. *Future Healthcare Journal*, 6, 181-185.
- Radianti, J., Majchrzak, T. A., Fromm, J., & Wohlgenannt, I. (2020). A systematic review of immersive virtual reality applications for higher education: Design elements, lessons learned, and research agenda. *Computers & Education*, 147, 103778.
- Real A.D., Real O.D., Sardina, S., & Oyonarte, R. (2022). Use of automated artificial intelligence to predict the need for orthodontic extractions. *Korean Journal of Orthodontics*, 52(2), 102–111.
- Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PloS one*, 10(3), e0118432.
- Sangalli, L., Alessandri-Bonetti, A., & Dalessandri, D. (2024). Effectiveness of dental monitoring system in orthodontics: A systematic review. *Journal of orthodontics*, 51(1), 28–40.
- Schwendicke, F., Chaurasia, A., Arsiwala, L., et al. (2021). Deep learning for cephalometric landmark detection: systematic review and meta-analysis. *Clinical oral investigations*, 25(7), 4299–4309.
- Schwendicke, F., Samek, W., & Krois, J. (2020). Artificial Intelligence in Dentistry: Chances and Challenges. *Journal of dental research*, 99(7), 769-774.
- Shin, W., Yeom, H. G., Lee, G. H., Yun, J. P., Jeong, S. H., Lee, J. H., Kim, H. K., & Kim, B. C. (2021). Deep learning based prediction of necessity for orthognathic surgery of skeletal

- malocclusion using cephalogram in Korean individuals. *BMC oral health*, 21(1), 130.
- T.C. Kişisel Verileri Koruma Kurumu. (2016). 6698 sayılı Kişisel Verilerin Korunması Kanunu.
- Thanathornwong B. (2018). Bayesian-Based Decision Support System for Assessing the Needs for Orthodontic Treatment. *Healthcare informatics research*, 24(1), 22–28.
- Tomášik, J., Zsoldos, M., Oravcová, Ľ., Lifková, M., Pavleová, G., Strunga, M., & Thurzo, A. (2024). AI and Face-Driven Orthodontics: A Scoping Review of Digital Advances in Diagnosis and Treatment Planning. *AI*, 5(1), 158-176.
- Topol E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature medicine*, 25(1), 44-56.
- Ünal, T., Kuran, A., Gulsen, I. T., Kızılay, F. N., Gulsen, E., Özüdoğru, S., Gördeli, K., Celik, O., Uğurlu, M., Bayrakdar, İ. Ş., & Orhan, K. (2025). Deep learning-based 3D automatic segmentation of impacted canines in CBCT scans. *BMC oral health*, 25(1), 1927.
- Volovic, J., Badirli, S., Ahmad, S., Leavitt, L., Mason, T., Bhamidipalli, S. S., Eckert, G., Albright, D., & Turkkahraman, H. (2023). A Novel Machine Learning Model for Predicting Orthodontic Treatment Duration. *Diagnostics (Basel, Switzerland)*, 13(17), 2740.
- Wang, X., Alqahtani, K. A., Van den Bogaert, T., Shujaat, S., Jacobs, R., & Shaheen, E. (2024). Convolutional neural network for

- automated tooth segmentation on intraoral scans. *BMC oral health*, 24(1), 804.
- Wartman, S. A., & Combs, D. (2018). Medical Education Must Move from the Information Age to the Age of Artificial Intelligence. *Academic Medicine*, 93, 1107-1109.
- Wong, K. F., Lam, X. Y., Jiang, Y., Yeung, A. W. K., & Lin, Y. (2023). Artificial intelligence in orthodontics and orthognathic surgery: a bibliometric analysis of the 100 most-cited articles. *Head & face medicine*, 19(1), 38.
- World Health Organization. (2021). Ethics and governance of artificial intelligence for health. WHO.
- Wu M. (2022). Application Research of Tooth Arrangement Based on Rotation Matrix Calculation and Resistance Detection in Oral. *Computational intelligence and neuroscience*, 2022, 4675181.
- Wu, J. L., Liu, Y. F., Peng, W., Dong, H. Y., & Zhang, J. X. (2018). A biomechanical case study on the optimal orthodontic force on the maxillary canine tooth based on finite element analysis. *Journal of Zhejiang University. Science. B*, 19(7), 535–546.
- Yang, S., & Cheng, Y. (2025). Force-Driven Model for Automated Clear Aligner Staging Design Based on Stepwise Tooth Displacement and Rotation in 3D Space. *Bioengineering (Basel, Switzerland)*, 12(2), 111.
- Zhou, W., Zhao, D., Zhao, B., Shen, M., & Liu, X. (2025). A deep learning framework for automated dental segmentation and diagnostic report generation from cone-beam computed tomography. *Head & face medicine*, 21(1), 80.



ISBN: 978-625-378-572-7