



TÜRKİYE CUMHURİYETİ
BEZMİÂLEM VAKIF ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

ORTOGNATİK CERRAHİ HASTALARINDA YAPAY ZEKA
ALGORİTMASINA SAHİP SEFALOMETRİK ANALİZLERİN DİJİTAL İKİ
VE ÜÇ BOYUTLU SEFALOMETRİK ANALİZLER İLE
KARŞILAŞTIRILMASI

UZMANLIK TEZİ

Enes TEMİZKAN

ORTODONTİ ANA BİLİM DALI

Ortodonti Uzmanlık Programı

TEZ DANIŞMANI

Dr. Öğretim Üyesi Banu KILIÇ

TEMMUZ 2024

TÜRKİYE CUMHURİYETİ
BEZMİALEM VAKIF ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

ORTOGNATİK CERRAHİ HASTALARINDA YAPAY ZEKA
ALGORİTMASINA SAHİP SEFALOMETRİK ANALİZLERİN DİJİTAL İKİ
VE ÜÇ BOYUTLU SEFALOMETRİK ANALİZLER İLE
KARŞILAŞTIRILMASI

UZMANLIK TEZİ

Enes TEMİZKAN

ORTODONTİ ANA BİLİM DALI

Ortodonti Uzmanlık Programı

Tez Danışmanı: Dr. Öğr. Üyesi Banu KILIÇ

TEMMUZ 2024

ÖNSÖZ

Her zaman yanımda olduklarını bildiğim, sevgi ve desteklerini her daim üzerimde hissettiğim sevgili eşim Cansu, canım oğlum Alperen, babam, annem ve kardeşlerim başta olmak üzere tüm aileme,

Uzmanlık eğitimim boyunca bilgi ve birikimleriyle bana yol gösteren; bu zorlu süreçte desteğini esirgemeyen, akademisyenliğiyle bana örnek olan çok değerli danışman hocam Dr. Öğr. Üyesi Banu KILIÇ'a

Bilgi ve tecrübeleriyle uzmanlık eğitimimde emeği geçen değerli hocalarım Prof. Dr. Gökmen KURT başta olmak üzere tüm hocalarıma,

Uzmanlık eğitimim boyunca maddi manevi destekleriyle her zaman yanımda olan, bu zorlu süreci güzelleştiren kıymetli arkadaşlarım Dt. Meral GÜRKAN, Dt. Duygu ÇAPKIN ve Dt. Muhammet Furkan ÖZDEN başta olmak üzere tüm arkadaşlarıma,

Sonsuz minnet ve teşekkürlerimi sunarım.

Temmuz 2024

Enes TEMİZKAN

Diş Hekimi

BEYAN

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

Enes TEMİZKAN

İÇİNDEKİLER TABLOSU

BEYAN	v
KISALTMALAR	viii
SEMBOLLER.....	ix
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xii
1 GİRİŞ VE AMAÇ	1
2 GENEL BİLGİLER.....	4
2.1 Sefalometrinin Tarihçesi	4
2.2 Lateral Sefalometrik Radyoloji	5
2.2.1 Lateral sefalometrik radyografilerin çekim prensipleri	6
2.3 Sefalometrik Radyografinin Kullanım Amaçları.....	7
2.4 Sefalometrik Radyografinin Limitasyonları.....	8
2.5 Görüntünün Elde Edilme Biçimine Göre Sefalometrik Radyografi Çeşitleri	10
2.5.1 Konvansiyonel sefalometrik radyografi.....	10
2.5.2 Dijital sefalometrik radyografi.....	10
2.6 Dijital Radyografik Görüntüleme Sistemleri.....	12
2.6.1 Doğrudan görüntüleme sistemleri.....	12
2.6.2 Doğrudan olmayan görüntüleme sistemleri	13
2.7 Lateral Sefalometrik Analiz Yöntemleri.....	13
2.7.1 Geleneksel sefalometrik analiz yöntemi (El ile çizim yöntemi)	13
2.7.2 Bilgisayar destekli dijital sefalometrik analiz yöntemi.....	14
2.8 Yapay Zeka.....	16
2.8.1 Yapay zeka eğitim verilerinde veri fazlalığı.....	18
2.8.2 Makine öğrenimi.....	19
2.8.3 Yapay sinir ağları.....	20
2.8.4 Yapay sinir ağı mimarileri	22
2.8.5 Derin öğrenme ve derin evrişimli sinir ağları	24
2.8.6 Evrişimli sinir ağı modelleri	27
2.8.7 Tekrarlayan sinir ağları (RNN).....	28
2.8.8 Uzun kısa vadeli hafıza ağları (LSTM)	28

2.8.9	Derin inanç ağıları (DBN)	29
2.8.10	Derin öğrenme kütüphaneleri	29
2.8.11	Görüntü işleme	29
2.8.12	Görüntü işleme teknikleri	30
2.9	Diş Hekimliğinde Yapay Zeka	31
2.10	Otomatik Sefalometrik Analiz ve Yapay Zeka	33
2.11	3B Görüntüleme Teknikler	34
2.11.1	Manyetik rezonans görüntüleme	34
2.11.2	Konik ışınlı bilgisayarlı tomografi	35
2.11.3	Bilgisayarlı tomografi	36
3	GEREÇ VE YÖNTEM	37
3.1	Veri Kaynağı ve Hasta Grupları	39
3.2	Yöntem	41
3.2.1	Çalışmada kullanılan sefalometrik noktalar	47
3.2.2	Çalışmada kullanılan sefalometrik ölçümler	50
3.2.3	İstatistiksel yöntem	60
4	BULGULAR	61
4.1	Bireylerin Yaş ve Cinsiyet Dağılımı	61
4.2	Sınıf İçi Korelasyon Katsayısı	61
4.3	NemoCeph 3D(Surgery FAB) Programında Yapılan Ölçümlerin NemoCeph (2D) Programı ve Yapay Zeka Programlarında Yapılan Ölçümlerinin Karşılaştırılması	62
4.4	Diğer Yöntemlerin NemoCeph 3D Programında Yapılan Ölçümlerden Farklarının Karşılaştırılması	70
5	TARTIŞMA	106
5.1	Amacın Tartışılması	106
5.2	Gereç ve Yöntemin Tartışılması	109
5.3	Bulguların Tartışılması	112
6	SONUÇLAR VE ÖNERİLER	118
	EKLER	132
	ÖZGEÇMİŞ	133

KISALTMALAR

<u>Kısaltmalar</u>	<u>Acıklama</u>
Ort	Ortalama
SS	Standart sapma
ark.	Arkadaşları
3B	3 Boyutlu
2B	2 Boyutlu
AC	AudaxCeph
OD	OrthoDx4
WC	WebCeph
mm	Milimetre
P	İstatistiksel anlamlılık
BT	Bilgisayarlı Tomografi

SEMBOLLER

Simgeler

Acıklama

- | | |
|---|---------------|
| ° | Derece |
| ‘ | Kesme işareti |



ŞEKİL LİSTESİ

Şekil 2.1:Sefalostat ile lateral sefalometrik röntgen çekimi[39]	9
Şekil 2.2: Lateral sefalometrik röntgen üzerinde çift görüntü.....	9
Şekil 2.3: Derin öğrenme metodunun diğer yapay zeka teknikleri ile olan ilişkisi[87].....	19
Şekil 2.4: Biyolojik sinir hücresi ve yapay sinir ağı[100].....	20
Şekil 2.5: Tek Katmanlı algılayıcıların model örneği[100].....	22
Şekil 2.6: Çok katmanlı algılayıcıların şematik gösterim örneği[107]	23
Şekil 2.7: a) Makine öğrenmesi modeli ve b) Derin öğrenme modeli [110].....	25
Şekil 2.8: DESA mimarisi modeli[112].....	26
Şekil 2.9: Piksel ifadesinin şematik gösterimi[125].....	30
Şekil 3.1: BT görüntülerinde işlem aşamaları	38
Şekil 3.2: Hasta seçim aşamaları	40
Şekil 3.3: BT görüntülerinin üst üste bindirilmesiyle elde edilen lateral sefalometrik görüntü	41
Şekil 3.4: BT görüntülerinin sol sagittal kesitlerinde NemoCeph 3D programında sefalometrik çizim	42
Şekil 3.5: BT görüntülerinin ideal midsagittal kesitlerinde NemoCeph 3D programında sefalometrik çizimi	42
Şekil 3.6: Nemoceph programında BT'den elde edilen 3 boyutlu görüntülerin sagittal kesitlerinin üst üste bindirilmesiyle elde edilen görüntülerin NemoCeph programında sefalometrik çizimi...	43
Şekil 3.7: Webceph tam otomatik sefalometrik analiz programında sefalometrik çizim.....	44
Şekil 3.8: Webceph tam otomatik sefalometrik analiz programında sefalometrik kalibrasyon	44
Şekil 3.9: Audox tam otomatik sefalometrik analiz programında sefalometrik çizim.....	45
Şekil 3.10: Audox tam otomatik sefalometrik analiz programında kalibrasyon	45
Şekil 3.11: OrthoDx tam otomatik analiz sefalometrik programında sefalometrik çizim	46
Şekil 3.12: OrthoDx tam otomatik analiz sefalometrik programında kalibrasyon.....	46
Şekil 3.13: OrthoDx tam otomatik sefalometrik analiz programında hatalı anatomik nokta işaretleme örneği	47
Şekil 3.14: Çalışmada kullanılan sert doku noktaları.....	49
Şekil 3.15: Çalışmada kullanılan yumuşak doku noktaları	50
Şekil 3.16: Çalışmada kullanılan doğru ve düzlemler.....	53
Şekil 3.17: Çalışmamızda değerlendirilen sagittal ölçümler.....	54
Şekil 3.18: Çalışmamızda değerlendirilen vertikal ölçümler	55
Şekil 3.19: Çalışmamızda değerlendirilen çene boyutu ölçümleri.....	56
Şekil 3.20: Çalışmamızda değerlendirilen üst keser ölçümleri	57
Şekil 3.21: Çalışmamızda değerlendirilen alt keser ölçümleri.....	58
Şekil 3.22: Çalışmamızda değerlendirilen yumuşak doku ölçümleri.....	59
Şekil 4.1: Yöntemlerin SNA ölçümünde karşılaştırılması	73
Şekil 4.2: Yöntemlerin SNB ölçümünde karşılaştırılması	74
Şekil 4.3: Yöntemlerin ANB ölçümünde karşılaştırılması	75
Şekil 4.4: Yöntemlerin N-A ölçümünde karşılaştırılması	76
Şekil 4.5: Yöntemlerin N-Pog ölçümünde karşılaştırılması.....	77

Şekil 4.6: Yöntemlerin Wits ölçümünde karşılaştırılması.....	78
Şekil 4.7: Yöntemlerin Y aksı açısı ölçümünde karşılaştırılması.....	79
Şekil 4.8: Yöntemlerin SN/GoMe ölçümünde karşılaştırılması.....	80
Şekil 4.9: Yöntemlerin SN/PP ölçümünde karşılaştırılması.....	81
Şekil 4.10: Yöntemlerin SN/GoGn ölçümünde karşılaştırılması	82
Şekil 4.11: Yöntemlerin FMA ölçümünde karşılaştırılması.....	83
Şekil 4.12: Yöntemlerin ön yüz yüksekliği ölçümünde karşılaştırılması.....	84
Şekil 4.13: Yöntemlerin arka yüz yüksekliği ölçümünde karşılaştırılması.....	85
Şekil 4.14: yöntemlerin arka-ön yüz yüksekliği oranı ölçümünde karşılaştırılması	86
Şekil 4.15: Yöntemlerin alt ön yüz yüksekliği oranı ölçümünde karşılaştırılması.....	87
Şekil 4.16: Yöntemlerin Co-A ölçümünde karşılaştırılması.....	88
Şekil 4.17: Yöntemlerin Co-Gn ölçümünde karşılaştırılması	89
Şekil 4.18: Yöntemlerin ön kafa kaidesi uzunluğu ölçümünde karşılaştırılması	90
Şekil 4.19: Yöntemlerin Go-Me ölçümünde karşılaştırılması.....	91
Şekil 4.20: Yöntemlerin UI/SN ölçümünde karşılaştırılması.....	92
Şekil 4.21: Yöntemlerin UI/PP ölçümünde karşılaştırılması.....	93
Şekil 4.22: Yöntemlerin UI-NA ölçümünde karşılaştırılması	94
Şekil 4.23: Yöntemlerin UI/NA ölçümünde karşılaştırılması	95
Şekil 4.24: Yöntemlerin UI/OP ölçümünde karşılaştırılması.....	96
Şekil 4.25: Yöntemlerin LI-Apog ölçümünde karşılaştırılması	97
Şekil 4.26: Yöntemlerin IMPA ölçümünde karşılaştırılması.....	98
Şekil 4.27: Yöntemlerin LI-NB ölçümünde karşılaştırılması.....	99
Şekil 4.28: Yöntemlerin LI/NB ölçümünde karşılaştırılması.....	100
Şekil 4.29: Yöntemlerin LI/OP ölçümünde karşılaştırılması	101
Şekil 4.30: Yöntemlerin interinsizal açı ölçümünde karşılaştırılması.....	102
Şekil 4.31: Yöntemlerin nasolabial açı ölçümünde karşılaştırılması	103
Şekil 4.32: Yöntemlerin üst dudak protrüzyonu ölçümünde karşılaştırılması	104
Şekil 4.33: Yöntemlerin üst dudak protrüzyonu ölçümünde karşılaştırılması	105
Şekil 5.1: Facealign Opencv açık kütüphanesinde bulunan veriler ile işaretlenen yumuşak doku anatomik noktaları.....	118

TABLO LİSTESİ

Tablo 4.1: Bireylerin yaş ve cinsiyet dağılımı.....	61
Tablo 4.2: Sınıf içi korelasyon katsayısı	61
Tablo 4.3: NemoCeph 3D(Surgery FAB) programı ile NemoCeph (2D) programında yapılan ölçümlerin karşılaştırılması	63
Tablo 4.4: NemoCeph 3D(Surgery FAB) programı ile AudoxCeph programında yapılan ölçümlerin karşılaştırılması	65
Tablo 4.5: NemoCeph 3D(Surgery FAB) programı ile OrthoDx programında yapılan ölçümlerin karşılaştırılması	67
Tablo 4.6: NemoCeph 3D(Surgery FAB) programı ile WebCeph programında yapılan ölçümlerin karşılaştırılması	69
Tablo 4.7: NemoCeph 2D, Audox, OrthoDx ve Webceph yöntemlerinin karşılaştırılması	71

ORTOGNATİK CERRAHİ HASTALARINDA YAPAY ZEKA ALGORİTMASINA SAHİP SEFALOMETRİK ANALİZLERİN DİJİTAL İKİ VE ÜÇ BOYUTLU SEFALOMETRİK ANALİZLER İLE KARŞILAŞTIRILMASI

Bu prospektif çalışmanın amacı çift çene ortognatik cerrahi gerektiren hastalarda cerrahi öncesinde BT'den elde edilen sefalometrik görüntülerden elde edilen 2 boyutlu görüntülerde yapay zekâ teknolojisiyle tabanlı tam otomatik sefalometrik analizleri bilgisayar destekli dijital sefalometrik analizler ve 3 boyutlu BT rekonstrüksiyonlarının sefalometrik ölçümleri ile karşılaştırmak ve yapay zeka tabanlı sefalometrik analizlerin yeterliliklerini değerlendirmektir.

Bu çalışmaya Bezmialem Vakıf Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalına başvuran ve yapılan ortodontik analizlerin sonucuna göre ortognatik cerrahi ile tedavi edilen 50 hasta dahil edilmiştir. Hastaların 23'ü erkek ve 27'si kadın hastanın BT görüntüleri dahil edilmiştir. Erkeklerin yaş ortalaması $25,30 \pm 5,83$, kadınların yaş ortalaması $23,96 \pm 5,61$ 'dir. Hastalardan alınan BT'ler Bezmialem Vakıf Üniversitesi Tıp Fakültesi Radyoloji Anabilim dalında tek bir tekniker tarafından standartlara uygun olarak çekilmiştir. Hastaların BT görüntülerindeki anatomik noktalar, NemoCeph 3D (SurgeryFAB) programında 3 boyutlu görüntülerin 2 boyutlu rekonstrüksiyonları ve iki boyutlu sefalometrik görüntüler kaydedilmiştir ve aynı programda işaretlenmiştir ayrıca Webceph, OrthoDx ve Audox programlarında yapay zeka ile otomatik olarak işaretlenmiştir.

Tüm istatistiksel analizler bir istatistik yazılım programında (SPSS versiyon 26.0, IBM Corp.) gerçekleştirilmiştir. Yöntemler NemoCeph 3D ile karşılaştırıldığında en yakın sonuçlara NemoCeph programında yapılan 2 boyutlu ölçümler ile ulaşılmıştır. Yöntemler kendi aralarında karşılaştırıldığında ANB değeri ($p=0,061$) dışındaki tüm ölçümlerde gruplar arasında istatistiksel olarak anlamlı farklılık bulunmuştur ($p<0,05$).

Çalışmamızda BT görüntülerinde 3 boyutlu analiz edilen doğrusal ve oransal ölçümlerin, BT görüntülerinin üst üste bindirilmesiyle oluşturulan 2 boyutlu sefalogram görüntüleri üzerinde yapılan ölçümlere yakın sonuç verdiği gösterilmiştir. Ortognatik cerrahi hastalarında tam otomatik sefalometrik analizler kullanılırken hatalı sefalometrik ölçümler yaptığı gözlemlenmiştir.

COMPARISON OF DIGITAL TWO-DIMENSIONAL AND THREE-DIMENSIONAL CEPHALOMETRIC ANALYSES WITH ARTIFICIAL INTELLIGENCE ALGORITHM-BASED CEPHALOMETRIC ANALYSES IN ORTHOGNATHIC SURGERY PATIENTS

The purpose of this prospective study is to compare fully automated cephalometric analyses based on artificial intelligence technology from 2D images obtained from cephalometric images taken before surgery in patients requiring bimaxillary orthognathic surgery with computer-aided digital cephalometric analyses and cephalometric measurements of 3D CT reconstructions and to evaluate the adequacy of AI-based cephalometric analyses.

Fifty patients who applied to the Department of Orthodontics at Bezmialem Vakıf University Faculty of Dentistry and were treated with orthognathic surgery based on the results of orthodontic analyses were included in this study. The CT images of 23 male and 27 female patients were included. The average age of the male patients was 25.30 ± 5.83 , and the average age of the female patients was 23.96 ± 5.61 . The CT scans taken from the patients were performed by a single technician in accordance with the standards at the Department of Radiology, Bezmialem Vakıf University Faculty of Medicine. Anatomical points in the CT images of the patients were recorded and marked in the NemoCeph 3D (SurgeryFAB) program, which reconstructs 3D images into 2D and cephalometric images. These points were also automatically marked using artificial intelligence in the Webceph, OrthoDx, and Audox programs.

All statistical analyses were performed using a statistical software program. When compared with NemoCeph 3D, the closest results were obtained with the 2D measurements performed in the NemoCeph program. When methods were compared among themselves, statistically significant differences were found between the groups in all measurements except for the ANB value ($p=0.061$) ($p<0.05$).

The results obtained in our study showed that orthodontists could use the linear and proportional measurements obtained from 3D CT in a manner similar to the methods used in the analysis of 2D cephalogram images created by the superimposition of CT images obtained with parallel rays that do not cause magnification. It was observed that fully automated cephalometric analyses made erroneous cephalometric measurements in orthognathic surgery patients.

1 GİRİŞ VE AMAÇ

Sefalometrik radyografiler, ilk kez Broadbent[1] tarafından tanıtıldığından bu yana, ortodontik teşhis, tedavi planlaması, iskeletsel büyüme tahmini ve tedavi sonuçlarının değerlendirilmesi için kullanılmıştır. Günümüzde sefalometrik radyografi analizleri, ortodontik teşhis için standart bir araç olarak kabul edilmektedir.

Geleneksel sefalometrik analiz, radyografi üzerinde yer alan anatomik noktaların belirlenmesini takiben açölçer ve cetvel kullanılarak gerçekleştirilir. Ancak, bu yöntem günümüzde klinik uygulama için pratik olmayan bir teknik olarak kabul edilmektedir. Zaman alıcı olması ve ölçüm sırasında hata yapma riski gibi nedenlerle tercih edilmemektedir [2, 3].

Dijital sefalometrik analizde, görüntü ya doğrudan ya da dolaylı olarak elde edilebilir. Görüntünün doğrudan dijital olarak elde edilmesi, asetat tabaka ve karanlık oda kullanımını ortadan kaldırır [4]. İlk ve ikinci nesil bilgisayar destekli sefalometrik görüntüleme yöntemleri, geleneksel sefalometrik radyografileri dijital hale getirmek için tarayıcılar ve dijital kameraları kullanır. Ancak, üçüncü nesil sistemler, sefalometrik görüntüyü doğrudan dijital olarak elde etme yeteneğine sahiptir ve elde edilen görüntüyü doğrudan sefalometrik analiz programlarına aktarabilir. Doğrudan dijital görüntülerin kullanımı, görüntüyü anında elde etme, daha az radyasyon dozu, görüntüyü işleme, paylaşma ve arşivleme kolaylıkları gibi önemli avantajlar sunmaktadır. Ayrıca, bilgisayar destekli dijital sefalometrik analiz, konvansiyonel yöntemle kıyasla oldukça hızlı bir şekilde gerçekleştirilebilir[5].

Dijital sefalometrik analiz alanında faaliyet gösteren NemoCeph, Dolphin Imaging, Dentofacial Planner, FACAD® gibi birçok bilgisayar programı geliştirilmiştir. Yapılan birçok bilimsel çalışma, konvansiyonel sefalometrik analiz ve bilgisayar destekli sefalometrik analiz yöntemlerini doğruluk ve güvenilirlik açısından karşılaştırarak, bu iki metodu birbirine yakın bulmuştur[6, 7].

Bilgisayar destekli tespit ve teşhis sistemleri, ortodontide otuz yılı aşkın bir süredir kullanılmaktadır.

Günümüz teknolojisiyle, araştırmacılar analiz için gereken noktaları işaretlerken, bilgisayar programları bu noktaları otomatik olarak tespit edip gerekli hesaplamaları yapmaktadır. Bilim insanları, ortodontik analiz için gereken noktaların bilgisayar tarafından otomatik olarak işaretlenmesi sayesinde insan kaynaklı hataları minimize etmeyi amaçlayan ve işlem süresini önemli ölçüde kısaltan programlar geliştirmek amacıyla çalışmaktadır[8-10].

Yapay zeka teknolojisinin hızla gelişmesi, günümüzde "tam otomatik" bir sefalometrik analiz gerçekleştirme olasılığını ortaya çıkarmıştır. WebCeph, OrthoDx, Ceph-X, AudaxCeph, WeDoCeph, CareStream Imaging gibi yapay zeka teknolojisini kullanan programlar, sefalometrik noktaların otomatik olarak işaretlenmesini ve analiz hesaplamalarını gerçekleştirmeyi amaçlamaktadır. Bu programlar, geleneksel yöntemlere kıyasla daha hızlı, daha kesin ve insan müdahalesini en aza indirerek analiz sürecini optimize etmeyi hedefler. Yapay zeka destekli sefalometrik analiz, ortodonti pratiğinde daha etkili teşhis ve tedavi planlaması sunma potansiyeli taşımaktadır. Bu tür yazılımlar, referans noktası tespiti için derin öğrenme tekniklerine veya konvolüsyonel sinir ağlarına dayanan yapay zekayı kullanır. Sistemik bir inceleme ve meta-analiz, derin öğrenmenin sefalometrik referans noktalarını bulmada yüksek doğruluğa sahip olduğunu bulmuştur[11]. Derin öğrenme sistemlerinde anatomik nokta işaretleme yeteneğinin yüksek doğruluğa sahip olduğu bulunmuş olsa da, ortodontistlerin bunu uygulamalarında güvenle kullanabilmeleri için bu özel yazılımın manuel referans noktası yerleştirme ile karşılaştırıldığında doğruluğu ve güvenilirliğini gösteren araştırmalara ihtiyaç vardır. Ayrıca derin öğrenme sistemiyle çalışan tam otomatik sefalometrik analiz programları elde ettikleri veri miktarı arttıkça daha doğru sonuçlar vermektedir. Ortognatik cerrahi hastaları gibi normalden uzaklaşmış değerlere sahip hastalarda anatomik noktaları işaretleyebilme kapasitesini ölçen bir çalışma bulunmamaktadır.

İlk ticari Bilgisayarlı Tomografi (BT) cihazının kullanıma sunulduğu 1972 yılına dayanmaktadır. Kısa bir süre sonra, üç boyutlu kesit görüntülerinin bilgi elde etmek için kullanılabileceği açıkça anlaşılmıştır. 1980'lerin başlarında, araştırmacılar bu teknolojiyi kraniofasial deformitelerin araştırılması için kullanmaya başlamışlardır. İlk simülasyon programı 1986'da kraniofasial cerrahi uygulamaları için geliştirilmiştir. Ardından, BT ve Manyetik Rezonans Görüntüleme (MRG) temellerini ve tekniklerini içeren ilk üç boyutlu görüntüleme ders kitabı 1980'lerin ortalarında yayımlanmıştır.

Daha sonraki yıllarda, üç boyutlu görüntüleme kendi disiplinini oluşturan, çeşitli tıbbi yapıların görselleştirilmesi, manipülasyonu ve analizi ile ilgilenen bir alan haline gelmiştir.[12]

Üç boyutlu medikal görüntülemelerde, diagnostik görüntüleme malzemeleri kullanılarak kaydedilen anatomik veriler bilgisayar tarafından işlenir ve daha sonra derinlik algısı sağlayacak şekilde iki boyutlu monitörlerde görüntülenir. Bu derinlik algısı, görüntülerin üç boyutlu olarak görülmesini mümkün kılar.[13]

Ortodontide üç boyutlu görüntülemenin uygulama alanları arasında diş-iskelet sistemi ilişkilerinin ve yüz estetiğinin ortodontik değerlendirmesi, yumuşak ve sert dokulara yönelik ortodontik sonuçların denetlenmesi, üç boyutlu tedavi planlaması ve özelleştirilmiş ark telleri gibi özel hazırlanmış üç boyutlu modellerin kullanımı bulunmaktadır. Yıllar boyunca, yüz yumuşak dokularını ölçmek için çeşitli yöntemler kullanılmıştır. Doğrudan antropometri, 2 boyutlu fotogrametri, lateral sefalometri, konik ışınlı bilgisayarlı tomografi (KIBT) ve yüzey tarama yöntemleri bu yöntemlerden bazılarıdır. Direkt antropometrik ölçüm, güvenilir ve uygun bir yöntem olmasına rağmen, zaman alıcı olması ve hasta uyumluluğu gerektirmesi gibi dezavantajları vardır. Fotogrametrik ölçümler genellikle frontal ve profil fotoğrafları kullanılarak yapılır. İki boyutlu görüntüler, dinamik bir nesnenin anlık görüntüsünü sunar ve bu nedenle yalnızca edinim sırasında iş birliği gerektirir, bu da doğrudan ölçümden daha kolay elde edilebileceği anlamına gelir. Bununla birlikte, iki boyutlu görüntüleme yöntemleri büyütme ve bozulma sorunlarına neden olabilir ve ölçme standardizasyonunu etkileyebilecek birçok değişkeni içerir. Ayrıca, üç boyutlu bir nesnenin iki boyutlu enine kesit görüntülerini değerlendirmek, önemli sınırlamalara sahiptir.[14-20]

Bu prospektif çalışmanın amacı çift çene ortognatik cerrahi gerektiren hastalarda cerrahi öncesinde BT'den elde edilen 2 boyutlu sefalometrik görüntüler üzerinde yapay zeka teknolojisiyle yapılan otomatik sefalometrik analizleri bilgisayar destekli dijital sefalometrik analizler ve BT rekonstrüksiyonlarının sefalometrik ölçümleri ile karşılaştırmak ve yapay zeka tabanlı sefaometrik analizlerin yeterliliklerini değerlendirmektir.

2 GENEL BİLGİLER

2.1 Sefalometrinin Tarihçesi

Baş ve yüz gelişimi ile kraniyofasiyal özelliklerin ilk bilimsel incelemeleri, farklı boyut ve şekillere sahip kafatasları üzerinde gerçekleştirilmiştir. Bu çalışmalar; antropologlar tarafından yürütülmüş, kafatasları üzerinde belirlenen çeşitli noktalardan ölçümler alınmış ve bu ölçümler kraniyometri olarak adlandırılmıştır[21]. Yapılan ölçümlerin doğruluğunu artırmak amacıyla, kafataslarını sabit ve tekrarlanabilir bir pozisyonda tutabilmek için kraniyostatlar tasarlanmıştır. Kraniyostatlar, günümüzde sefalometrik görüntüleme sırasında hastanın başını sabitlemeye yardımcı olan, sefalostatların atası olarak kabul edilebilir[22].

Kafatasları üzerinde açısal ölçümleri ilk yapan bilim adamlarından biri olan Camper, 1780 yılında, dış kulak yolundan burunun tabanına çizilen çizginin yüz profiline teğet olarak çizilen bir çizgiyle kesişmesi sonucu oluşan açının, yüz ve kafa yapısını tanımlamak için önemli bir ölçüt olduğunu açıklamıştır[23].

Kraniyometri, çalışma alanları dışında kaldığı için çoğu ortodontistin ilgisini çekmemiştir. Ancak, daha sonraki dönemlerde kraniyometrik çalışmalar yaşayan canlılar üzerinde de yapılmaya başlanmış ve "sefalometri" adını almıştır [24]. Sefalometrik çalışmalar, ortodontistler tarafından ilgi görmüş ve geliştirilmiştir. Kraniyometrik çalışmalar ve profil röntgenografisi ile ilişkilendirilen bir dizi çalışma gerçekleştirilmiştir. Örneğin, 1885 yılında Almanya, Frankfurt'ta gerçekleşen Uluslararası Antropoloji Kongresi'nde, Van Ihcring'ın dış kulak yolunun üst kenarından göz çukuru tabanına çizdiği çizgi, antropolojik çalışmaların sefalometrik röntgene uyarlanmasıyla ilk örneklerinden biridir ve günümüzde lateral sefalometride sıkça kullanılan Frankfort horizontal düzleminin öncüsü olarak kabul edilir [22]. 1920'li ve 1930'lu yıllarda antropolojik tekniklerin ortodonti alanına uyarlanmasıyla ilgili birçok çalışma yapılmıştır[22].

X-ray ışınlarının 1895 yılında William Röntgen tarafından keşfedilmesinden kısa bir süre sonra, kafa röntgenleri klinisyenler tarafından gelişimsel sorunların, sendromların ve hastalıkların teşhisinde kullanılmaya başlanmıştır[22].

1896'da Welcker, kafa bölgesinden elde edilen röntgen görüntülerinin, bu bölgedeki anormallikleri tespit etmede ve hastalıkları teşhis etmede önemli olabileceğini bildirmiştir[23].

1921 yılında Pacini, röntgen ışını antropometrisinin sağladığı ölçüm doğruluğunun sıradan antropometriden elde edilenin önemli ölçüde üzerinde olduğunu belirtmiştir. Pacini'nin çalışmasında, deneğin başı medyan sagittal düzlemle film arasında hizalanmış, baş dikey bir başlık ile desteklenmiş ve film tutucusuna bağlanarak hareketsiz hale getirilmiştir [22]. Kendi geliştirdiği bu yöntemle elde edilen röntgenler üzerinde, gonion, pogonion, nasion, spina nasalis anterior, sella turcica'nın orta noktası (turcicon), meatus acusticus externus'un üst noktası (acustion) gibi çeşitli antropolojik noktaları tanımlamıştır [25].

McCowen, profil röntgenografisini 1923 yılında ortodonti pratiğinde sert ve yumuşak dokular arasındaki ilişkiyi incelemek ve ortodontik tedavi sonrası profildeki değişiklikleri gözlemlemek için kullanmıştır. McCowen'ın çalışmasında, ardışık olarak alınan sefalometrik radyografiler arasında sağlıklı bir değerlendirme yapabilmek için radyografi alım tekniğinin standartlaştırılmasının önemine vurgu yapmıştır [26].

1924 yılında Carrea, yeni bir sefalometrik görüntüleme tekniği tanıtmıştır. Bu yöntemde ışın kaynağı ve obje mesafesi 2 metre olarak belirlenmiş, bu da görüntüdeki bozulmaları azaltmaya yardımcı olmuştur. Araştırmacı, bu yöneme "teleradiofacie" adını vermiştir. Carrea, yumuşak doku profilini belirlemek için ince bir kurşun tel kullanmış ve dış kulak yolunu belirleyebilmek için kulağa küçük kurşun tüpler yerleştirmiştir [27].

1931 yılında yayımlanan "Yeni Bir X Işın Tekniği ve Ortodontiye Uygulanması" adlı makalesinde, Broadbent, daha önceki tekniklerden daha gelişmiş bir yöntem sunarak sefalometriyi ortodonti literatürüne resmen tanıtmış ve sefalometrik çalışmaların büyük bir ivme kazanmasına öncülük etmiştir[1].

2.2 Lateral Sefalometrik Radyoloji

Şu anda ortodonti uygulamalarında, ortodontik sorunların tanısı ve tedavi planlaması sırasında, klinik muayene bulgularına ek olarak hastanın fotoğrafları, ağız içi modelleri ve radyografiler gibi görüntüleme teknikleri kullanılmaktadır. Sefalometri, birçok kısıtlılığa sahip olmasına rağmen, klinik teşhis için önemli bir yöntemdir[28].

Sefalometrik radyografi terimi, genellikle yaygın olarak kullanılan lateral sefalometrik radyografik görüntüleme yöntemini çağrıştırmaktadır. Lateral sefalometrik radyografilerle baş, sadece sagittal ve vertikal yönler odaklanarak değerlendirilebilmektedir. Başın sagittal, vertikal ve horizontal yönler dair üç boyutta kapsamlı bir değerlendirme yapılabilmesi için, lateral sefalometrik radyografilere ek olarak posteroanterior (PA) ve submentoverteks (SMV) radyografik projeksiyonları da kullanılmalıdır[29].

2.2.1 Lateral sefalometrik radyografilerin çekim prensipleri

Sefalometrik görüntülemenin temel ilkesi standardizasyondur. Anlamlı bir sefalometrik analiz için karşılaştırılan veya çakıştırılan sefalometrik radyografilerin benzer koşullarda çekilmiş olması gereklidir. Görüntüde hata oluşmaması için hastanın pozisyonu ve X ışınlarının yönelimi, film çekilirken değişmemelidir. Görüntü distorsiyonunu en aza indirmek için ışın kaynağı-obje/birey uzaklığı yeterince büyük, film-kaset uzaklığı ise küçük tutulmalıdır[1].

Sefalostatta lateral sefalogram çekilirken, ışın kaynağı, her iki kulak ve kasetin merkezi aynı eksende olmalıdır. Bu şartlar sağlandığında, her iki kulak çıkıntısının görüntüsünün çakışmasıyla kontrol yapılabilir[30].

Sefalostatlarda başı sabitleyen bölüm, kulak çıkıntılarına ve burun kemerine dayanan bir çubuktan oluşur. Sefalostatın dış kulak yolu kısımları, röntgen çekilecek bireyin başına yerleştirilir. Başın Frankfurt düzlemine paralel bir konumda olmasını sağlamak için, sefalostatın orbita çubuğu bireyin sol tarafındaki orbita üzerine hizalanır. Bu sayede baş, en fizyolojik konumunu alır. Daha sonra burun çıkıntısı, nasion noktasına doğru ayarlanır[31].

Işın kaynağı ile birey arasındaki uzaklık genellikle 1 metre 52 cm olarak belirlenir. Birey ile film kaseti arasındaki uzaklık ise farklı tekniklere göre değişkenlik gösterir.

Modern sefalostatlarda, bireyin orta oksal düzlemi ile film kaseti arasındaki mesafe genellikle 13 cm olarak kabul edilmektedir. Profil röntgenlerinde sefalometrik oryantasyon sağlanırken, ışın kaynağı her zaman Frankfurt horizontal düzlemine göre, hasta ayaktayken veya otururken orta oksal düzleme ve kasete dik olmalıdır [31]. Sağ ve sol kulak delikleri, ön-arka ve dikey sapma

göstermeden üst üste gelmelidir. Eğer sapma, alt çene kenarlarında çift bir görüntü ile birlikte ortaya çıkarsa, hasta sefalostatta yanlış bir konumda bulunabilir[30].

2.3 Sefalometrik Radyografinin Kullanım Amaçları

Sefalometrik radyografiler, hastadaki anomalinin dişsel ya da iskeletsel kaynaklı olduğuna karar vermek, büyüme ve gelişim sırasında, ortodontik tedavi sırasında ve sonrasında meydana gelen değişimleri gözlemlemek amacıyla kullanılabilir[32].

Sefalometrik radyografi kullanım amaçlarını Ricketts 1961 yılında 4C (characterised, compared, classified, communicated) kuralı ile özetlenmiştir;

Karakterize etme (characterise): Anomalinin; patolojik, morfolojik veya anatomik olduğunu tanımlamaya yarar.

Kıyaslama (compare): Aynı veya farklı bireylerden farklı zamanlarda alınmış radyografiler arasından kıyas yapmaya yarar.

Sınıflama (classify): İskeletsel ve dişsel bakımdan, çene, çene kemiği ve dişler düzeyinde çeşitli sınıflamalar yapmaya yarar.

İletişim kurma (communicate): Hastanın dişsel ve iskeletsel açıdan o anki durumunu diğer hekimlerle veya hasta yakınlarıyla paylaşmaya yarar.

Ortodonti klinisyenleri, kraniyofasiyal yapının görselleştirilmesinde genellikle iki boyutlu statik görüntülerden yararlanırlar. Lateral sefalometrik görüntüler, ön-arka yönden iskeletsel yapı ile diş yapısını ve bunların yumuşak dokuyla olan ilişkisini incelemek için kullanılırken, posteroanterior sefalometrik görüntüler ise transversal yöndeki iskeletsel ve dişsel ilişkilerin incelenmesine olanak tanır; ayrıca iskeletsel ve dental asimetrielerin tespiti için de kullanılırlar[33].

Kraniyofasiyal görüntüleme, dişsel ve iskelet yapısının mevcut durumu ile ortodontik tedavinin neden olacağı değişiklikleri, bireyin gelişimi sırasında ortaya çıkabilecek karmaşık değişikliklerin yorumlanması veya aşağıdaki kategorilerin bir veya birkaçının incelenmesi amacıyla kullanılmaktadır[33];

Normal ve anormal anatomik yapının tespiti

Kök uzunluğunun ve hizalarının incelenmesi

Çenelerin boyutu ve gerekli olan mesafe arasındaki ilişkinin saptanması

Alt ve üst çenenin uzaysal ilişkisinin saptanması

Temporomandibular eklemin durumunun tespiti

Kraniyofasiyal gelişme boyutunun ve yönünün tahmin edilmesi

Tedavinin kraniyofasiyal yapılar üzerindeki etkilerinin gözlenmesi


Supernumerer ve gömülü dişlerin tespiti

2.4 Sefalometrik Radyografinin Limitasyonları


Kraniyofasiyal yapıların üç boyutlu yapısı, sefalometrik radyografilerde genellikle iki boyutlu olarak görüntülenir. Görüntüleme sırasında anatomik yapılar üst üste gelir ve bu durum bazı anatomik yapıları birbirinden ayırt etmeyi zorlaştırabilir. Bu nedenle tam olarak doğru bir tedavi planlaması yapabilmek için, lateral sefalometrik radyografilerin yanı sıra posteroanterior sefalometrik radyografi ve submentoverteks radyografilerin de alınıp incelenmesi gerekmektedir [34-36].

Küçük bir kaynaktan çıkan X ışınlarının birbirlerine paralel olmaması ve diverjan bir şekilde yayılması nedeniyle görüntüde genişlemeler meydana gelir. Bu genişlemeyi en aza indirmek için, obje ile film arasındaki mesafe mümkün olduğunca azaltılmalı ve obje ile X ışını kaynağı arasındaki mesafe artırılmalıdır[37].

Sefalometrik landmarklar ve anatomik yapılar genellikle midsagittal düzlem üzerinde olsada bir kısmı çift taraflıdır. Bu durum, radyografi üzerinde çift görüntü oluşturur. Bilateral yapılar simetrik olsa bile, X ışınlarının diverjan bir şekilde yayılması ve bu referans noktalarının filme olan uzaklıklarının farklı olması nedeniyle farklı oranlarda büyütme gösterirler ve film üzerinde örtüşmezler[38].



Şekil 2.1:Sefalostat ile lateral sefalometrik röntgen çekimi[39]



Şekil 2.2: Lateral sefalometrik röntgen üzerinde çift görüntü

Referans noktalarının yeterince iyi gözlemlenememesi, görüntü alanı üzerindeki gölgeler ve hasta pozisyonlarının çeşitliliği, anatomik noktaların belirlenmesinde hatalara neden olabilir. Bu hatalar, bazı araştırmacılar tarafından sefalometrik analizdeki yanlışlıkların en önemli sebeplerinden biri olarak vurgulanmaktadır[36, 40-43].

2.5 Görüntünün Elde Edilme Biçimine Göre Sefalometrik Radyografi Çeşitleri

2.5.1 Konvansiyonel sefalometrik radyografi

Konvansiyonel sefalometrik radyografiler; çene kemiklerinin, dişlerin ve yüzün lateral görüntüsünü elde etmek için kullanılan ağız dışı bir radyografi türüdür. Görüntü, X ışınlarının film üzerine düşürülmesi yoluyla elde edilir, bu film de kasetin içine yerleştirilmiştir.

Film, kasetin içindeki iki ranforsatör arasında bulunur. Dıştan içe doğru, film sırasıyla koruyucu tabaka, emülsiyon tabakası, yapıştırıcı tabaka ve baz tabakadan oluşur. X ışınlarına duyarlı gümüş halid kristallerin bulunduğu tabaka, emülsiyon tabakasıdır[44].

X ışını dokuya düştüğünde, dokuların farklı yoğunluklarda olması nedeniyle farklı oranlarda emilir ve film üzerinde açık ve koyu renkli görüntüleme alanları oluşur. Işınlanmış film banyo işlemlerine tabi tutulduktan sonra radyografik görüntü elde edilir[44].

Geleneksel sefalometrik radyografi, günümüzde yaygın olarak kullanılan dijital görüntüleme tekniklerine kıyasla bir dizi olumsuzluğa sahiptir. Bu görüntüleme biçiminde, görüntünün elde edilme süreci zaman alıcıdır. Film üzerindeki kimyasal işlemlerin süresine bağlı olarak görüntü kalitesinde değişiklikler gözlenebilir. Ek olarak, bir defa elde edildikten sonra görüntü üzerinde değişiklik yapma imkânı bulunmamaktadır[45].

2.5.2 Dijital sefalometrik radyografi

Dijital sefalometrik radyografide, görüntüler X ışınlarının sensörler üzerine düşürülmesiyle elde edilir. Görüntü, elektronik olarak bilgisayara aktarılabilir ve dijital olarak görüntülenebilir. Temel fark, görüntü elde edilirken sensörlerin kullanılması ve görüntüyü oluşturmak için kullanılan yöntemlerden kaynaklanmaktadır[46].

Dijital görüntü, piksellerin bir araya gelmesiyle oluşur. Görüntüyü oluşturan piksellerin boyutları küçüldükçe çözünürlük artar ve daha detaylı bir hal alır[47]. Dijital radyografi tekniklerinin hızla ilerlemesi, günümüzde konvansiyonel radyografinin yerini tamamen dijital görüntüleme sistemlerine bırakmıştır[48].

Dijital radyografi, bilgilerin işleme sürecinde konvansiyonel yöntemle göre daha hızlıdır. Elde edilen görüntü daha sonradan değiştirilebilir ve geliştirilebilir[47, 49]. Ekspozür esnasında meydana gelen hatalar düzeltilebilir. Böylece tekrarlanan pozlamalara ihtiyaç duyulmaz[50]. Çekilen seri radyografların bilgisayar ortamında karşılaştırılması mümkündür[51]. Görüntünün kolayca çoğaltılması uygun maliyetlidir[6]. Bazı dijital görüntüleme sistemlerinde gereken radyasyon oranı, konvansiyonel sistemlere kıyasla daha düşüktür[52]. Dijital radyografi sistemi kullanımıyla işlem süresi önemli ölçüde azalmıştır[46].

2.5.2.1 Dijital sefalometrik görüntü kalitesini etkileyen faktörler

Çözünürlük:

Bir görüntüyü elde etmek için gereken piksel sayısını ifade eder. Görüntüyü meydana getiren piksel sayısının artması, her bir pikselin daha ince ayrıntılara karşılık gelmesini ve daha keskin bir görüntünün oluşmasını sağlar. Orijinal görüntü kalitesini sürdürebilmek için çözünürlük miktarının yüksek olması gerektiği gibi, aynı zamanda görüntüyü oluşturan piksellerin boyutunun da 0.1 mm'den küçük olması önemlidir[53].

Optik Yoğunluk:

Radyografinin siyahlık miktarının ölçüsüdür ve filme düşen ışık miktarının filmde geçen ışık miktarına oranı ile hesaplanır. Gri tonlar arasındaki farklar radyografinin siyahlık oranını belirler. Dijital ortamda bilgi aktarımı, en küçük birim olan "bit" aracılığıyla gerçekleştirilir. Bilgisayarlar, genellikle çok sayıda bit içeren parlaklık değerlerini kullanırlar. Örneğin, 8-bit sistemde 256 gri değeri bulunur (0 en koyu siyah, 255 en açık beyaz değerine denk gelirken, aradaki 254 değer farklı koyulukta gri tonlarına karşılık gelir). Dijital görüntü kalitesini etkileyen şey, bu gri ton yelpazesinin (gri skalası) genişliğidir[53].

Görüntüleme:

Görüntü ekranlarının çözünürlüğü genellikle çizgi sayısına (raster lines) göre değişir. Dijital görüntüler genellikle 625 çizgiye sahip ekranlarda görüntülenir. Ekranların çizgi sayısının 2048 olduğu durumları kullanmak, radyografik filmin orijinal kalitesine yakın bir görüntü elde etmemize olanak tanır[53].

2.6 Dijital Radyografik Görüntüleme Sistemleri

Dijital görüntüleme sistemlerinde, görüntü elde etmek için iki farklı yöntem bulunmaktadır: Doğrudan ve dolaylı teknik. Doğrudan tekniğin kullanıldığı durumda, görüntü, herhangi bir geçiş formu kullanmadan doğrudan dijital veri olarak ekranda görüntülenir. Bu yöntem günümüzde oldukça yaygın olarak tercih edilmektedir.

Dolaylı görüntüleme tekniğinde ise, önce konvansiyonel bir radyografi çekilir ve ardından tarayıcı kullanılarak bu görüntü dijital formata dönüştürülür[54].

2.6.1 Doğrudan görüntüleme sistemleri

Sensörler (katı hal dedektörleri) ve ışıkla uyarılabilir fosfor plaklar olmak üzere 2 temel gruba ayrılır.

Sensörler (SST): Yarı iletken ve katı maddeden üretilen sensörler, X ışını enerjisini içlerinde toplar ve herhangi bir ek işleme gerek olmaksızın görüntü oluşturabilirler[55].

CCD (charged coupled device): Elektronik devreye sahip silikon çip içeren sistemlerdir. X ışını; çip üzerine düştüğünde, elektronlar serbest bırakılarak bir elektronik şarj meydana gelir. Elde edilen latent görüntü, kablolar aracılığıyla bilgisayara aktarılır ve dijital veriye dönüştürülerek görüntülenir[56].

CMOS (Complementary Metal Oxide Semiconductors): Video kamera dedektörü inşasında kullanılan bu sistem, CCD tip sensörlerde olduğu gibi silikon temellidir. Ancak; piksel şarjının okunma mekanizması, CCD tip sensörlerden farklılık arz eder[55].

Plat Panel Detectors: Ağız dışı radyografi alımında kullanılan bu sistem, başın tamamı gibi daha büyük yapıların görüntülenmesine olanak sağlayan 100 mikrometre veya daha küçük piksel

boyutlarına sahiptir. Sensörler, amorf silikon materyalinden türetilmiştir. Bu sistem, diğerlerine göre daha yüksek maliyetli olup özellikle konik ışın BT gibi özel görüntüleme yöntemlerinde tercih edilmektedir[55].

Işıkla Uyarılabilir Fosfor Plakaları (PSP): Bu metotta, görüntü elde etmek için fosfor plakaları kullanılır. Yaklaşık 1 mm kalınlığında olan ve baryum florit tabakasıyla kaplı bu ince plakaya X ışını düştüğünde latent bir imaj meydana gelir. Plakanın içinde saklı kalan latent imaj, lazer tarayıcıyla okutularak bilgisayara dijital bir formatta transfer edilir. Tarayıcıdan çıkarılan plakanın fosfor tabakası, ışınlanmadan önceki durumuna geri döndüğü için tekrar tekrar ışınlanabilir[48].

2.6.2 Doğrudan olmayan görüntüleme sistemleri

Konvansiyonel radyografilerin tarayıcıdan geçirilerek dijital görüntünün elde edildiği sistemlerdir. Tarayıcının film üzerinden geçen parçasının yaydığı ışık, filmin alt kısmında bulunan çipli sistem tarafından algılanır. Filmden geçen ışığın yoğunluğuna göre koyu ve açık renkli kısımlar, gri renk skalasında dijital görüntü olarak monitörde izlenir [54].

2.7 Lateral Sefalometrik Analiz Yöntemleri

2.7.1 Geleneksel sefalometrik analiz yöntemi (El ile çizim yöntemi)

Sefalometrik analiz, uzun yıllardır kullanılan bir yöntemdir. Bu yöntemde, radyografi üzerine yerleştirilen asetat kâğıdı sabitlenir ve analiz için belirlenen noktalar işaretlenerek çeşitli düzlemler çizilir. Bu çizilen düzlemler üzerinden yapılan açısal ve doğrusal ölçümler kaydedilir. Ardından değerlendirme yapılır. Ancak, bu yöntem zaman alıcı olup hata yapma olasılığı yüksektir.[57, 58].

Radyografik görüntü elde edilirken; ışınlama veya görüntü oluşumu sırasında, işaretlenen referans noktaların birleştirilmesinde veya ölçüm tekniğinde hatalar meydana gelebilir. Bu hataların büyük bir kısmı, araştırmacının deneyimsizliğinden ve görüntünün yoğunluğu ve netliği gibi faktörlerden etkilenen referans noktalarının yerinin belirlenmemesinden kaynaklı ortaya çıkar. [40, 59].

2.7.2 Bilgisayar destekli dijital sefalometrik analiz yöntemi

Bilgisayarlı sefalometrik analiz yöntemi, programların araştırmacılar tarafından yüklenmiş verileri kullanarak analiz yapmasını içerir. Bu veriler, birçok araştırmacının yaptığı analizleri içerir. Dijital ortamdaki sefalometrik radyografilerde referans noktaları işaretlenir ve analiz sonuçları saniyeler içinde elde edilir. Bu analiz, bilgisayar tarafından gerçekleştirildiği için, araştırmacılar tarafından ölçümler sırasında yapılan hataları ortadan kaldırdığı iddia edilmektedir.[57]

Diğer taraftan, referans noktaların araştırmacı tarafından belirlendiği bilgisayarlı sefalometrik analiz yönteminde de geleneksel sefalometrik analiz yöntemine benzer hataların oluşabileceği belirtilmiştir[60].

Bilgisayarlı sefalometrik analiz sistemleri genellikle birinci, ikinci ve üçüncü jenerasyon sistemleri olarak sınıflandırılabilir.

Birinci Jenerasyon Sistemler

Referans noktalarını bilgisayar ortamına aktarmak için dijitizer ve cursor olarak adlandırılan ekipmanlara ihtiyaç vardır. Dijitizer, referans noktalarının X ve Y düzlemindeki koordinatlarını kaydeden bir aygıttır. Cursor ise referans noktalarını işaretlemek için kullanılır. Dijitizer, cursora temas ettiği zaman meydana gelen elektrik akımını kablolar aracılığıyla bilgisayara iletilir. Dijitizerler opak, radyolüsent veya transparan olabilir. Asetat kağıda ihtiyaç duymadan radyografi üzerinden doğrudan dijitalasyon sağladığı için çizim sırasında asetat tabakasına bağlı hataları ortadan kaldırırlar[35].

Dijitizerler, off-line ve on-line olmak üzere iki farklı tipe ayrılabilir.

Off-Line Dijitizerler: Radyografi dijitalize edildikten sonra bilgiler sabit diske kaydedilir. Daha sonra kaydedilen bilgiler üzerinden analiz gerçekleştirilir.

On-Line Dijitizerler: İşaretleme noktaları doğrudan bilgisayara aktarılır. İşaretleme ve analiz eş zamanlıdır. Doğrudan ekrandan izlenebilir.

Bu işlemler esnasında iki farklı dijitalasyon modeli kullanılmaktadır.

Point mod dijitalasyon: İşaretlenecek noktalar ayrı ayrı belirlenir. Tanımlaması önceden yapılmış olan noktaların koordinatları operatör tarafından cursor kullanarak tespit edilir. Her bir noktanın X ve Y ekseni koordinatları bilgisayara aktarılır. Filmin orijinal konturları sabit tutularak işaretleme noktalarının birleşmeleri ile radyografinin sanal hali oluşturulur.

Stream mod dijitalasyon: Bu modda, radyografik konturlar manuel olarak çizilir. Komşu birçok nokta birbirine transfer edildikten sonra, radyografi konturları el ile çizilir. Point mod dijitalasyona kıyasla daha az zaman alıcıdır, ancak konturların doğru bir şekilde tespiti deneyim gerektirir.[61]

İkinci Jenerasyon Sistemler

Bu nesil sistemlerde dijitalizer ve cursora ihtiyaç duyulmamaktadır. Tarayıcı ya da dijital kameralar kullanılarak dijital hale getirilip bilgisayara aktarılan görüntü üzerinde işaretleme fare kullanılarak yapılmaktadır[62].

Üçüncü Jenerasyon Sistemler

Bu sistemlerde CCD, PSP reseptörler veya doğrudan dijital sistemler kullanılarak elde edilen görüntüler, bilgisayara dijital görüntü olarak aktarılır ve bilgisayar üzerinde işaretleme ve ölçüm işlemleri gerçekleştirilir. Radyografiyi dijital hale dönüştürmek için tarayıcı veya kamera kullanma gereksinimi ortadan kalkar. Doğrudan dijital görüntü elde edildiği için gereken ışınlama dozunun daha düşük olması, görüntüleri işleme, gönderme ve arşivleme işlemlerinin daha kolay ve hızlı olması açısından daha avantajlıdır[46, 50, 62].

2.7.2.1 Bilgisayar destekli dijital sefalometrik analiz yazılımları

Günümüzde birçok marka adı altında ticari amaçlı bilgisayar destekli dijital sefalometrik analiz programları bulunmaktadır. Bu programlardan bazıları şunlardır: Ceph Smile Plus, Dentofacial Planner, Dentrax Image, Dolphin, Dr. Ceph, Dr.Ceph Jr., Dr.View, IOPS, JOE, Nemoceph, Niamtu Imaging Systems, Onyx Ceph, OPAL, Orthoview-Ceph, Prescription Planner/Portrait, Quick Ceph 2000, Screenceph, T PhotoEze, Vistadent.

Yukarıda bahsedilen dijital sefalometrik analiz programlarının güvenilirliğini değerlendiren[2, 58, 63-73] ve geleneksel yöntemlerle karşılaştıran çalışmalar bulunmaktadır[6, 74-78].

Bu alıřmalar, dijital sefalometrik analiz programlarının birbirleriyle ve geleneksel yntemlerle karřılařtırılmasıyla ilgilenmiřtir. Dijital sefalometrik analiz programlarını birbirleriyle ve konvansiyonel yntemlerle kıyaslayan arařtırmalar, klinik alıřma sresini nemli lde kısaltan dijital sefalometrik analiz programlarının, ortodonti kliniklerinde konvansiyonel analiz yntemleri yerine gvenle kullanılabileceğini belirtmiřtir[79-82].

2.8 Yapay Zeka

Yapay zeka (YZ), yaygın olarak akıllı davranıř olarak adlandırılan olgunun sayısal olarak anlařılmasıyla ve bu tr davranıřları sergileyen eserlerin yaratılmasıyla ilgilenen bir bilim ve mhendislik alanı olarak tanımlanır. Aristoteles, kuramları ( kısımlı tmdengelimli bir akıl yrtme) aracılıęıyla 'doęru dřnmeyi' (mantık) resmileřtirmeye alıřmıř. Modern aędaki alıřmaların oęu bundan ilham almıř ve zihnın iřleyiři zerine yapılan ilk alıřmalar aędař mantıksal dřncenin kurulmasına yardımcı olmuřtur.[83] İnsan ve bilgisayar etkileřimi, ilk kez 1945 yılında Vannevar Bush'un "As We May Think" adlı makalesinde ele alınmıřtır. Bu makalede Bush, "Memex" adını verdięi hayali bir makineden sz etmektedir. Makalede, kullanıcı Memex'te Trk yayı ve okunun ne kadar iyi olduęunu arařtırmakta, arařtırma sonularını kaydetmekte ve bunları arkadařına gndermektedir. Makale ayrıca Trklere yapılan ilk atıflardan biri olarak kabul edilmektedir[84]. Yapay akıllı sistemler, insan benzeri zeka ve karar verme yeteneklerine sahip olmak zere tasarlanmıř ve programlanmıř bilgisayar sistemleri veya makineler olarak tanımlanabilir. İngiliz matematiki Alan Turing (1950), modern bilgisayar biliminin ve yapay zekanın kurucusu olarak kabul edilir. 1950'de Alan Turing tarafından yapılan arařtırma, makinelerin insanlarla aynı dzeyde dřnme yeteneęine sahip olup olmayacağını arařtırmaya bařladı. Turing, bir makinenin akıllı olup olmadığını belirlemek iin kullanılabilecek bir test nermiř ve bu daha sonra 'Turing testi' olarak popler hale gelmiřtir. Test artık yapay zekanın temel tařı olarak kabul edilmektedir[85]. Bir matematiki olan John McCarthy, 1955'te YZ terimini ortaya attı ve yaygın olarak yapay zekanın babası olarak kabul edildi. Bu terimi, makinelerin "akıllı" faaliyetler kapsamına girebilecek grevleri gerekleřtirme potansiyelini aıklamak iin seti. 1956 yılında, John McCarthy, resmi olarak yapay zeka arařtırma projesi zerine olan nl bir Dartmouth konferansını dzenledi. Konferans, 1950'lerden 1970'lere kadar, YZ zerinde kapsamlı arařtırmaların yapıldığı kritik dnemi ateřledi. Prof. Dr. Cahit Arf, Trkiye'de dzenlenen "Makineler Dřnebilir mi?" bařlıklı konferansta bir konuřma yaptı.

1958'de "Bir makine nasıl düşünür?" sorusunu sordu. Profesör Arf, uygulanabilir olduğunu iddia ederek kendi başına düşünebilen bir makine yaratma fikrini örneklendirdi. 1978'de uygulamalı bir matematikçi olan Richard Bellman yapay zekayı; öğrenme, karar verme ve problem çözme içeren insan düşünme yetenekleriyle ilişkili faaliyetlerin otomasyonu olarak tanımladı.

Günümüz dünyasında yapay zeka, problem çözme gibi insan bilişsel becerilerini taklit edebilen herhangi bir makine veya teknolojiyi ifade eder[86].

Yapay zeka geniş bir terim olmasına ve çeşitli sınıflandırmaları içermesine rağmen, iki ana yapay zeka kategorisi vardır: Sembolik yapay zeka ve algoritmik açıdan makine öğrenimi. Sembolik YZ, algoritmanın insan tarafından okunabilir sembolik bir şekilde yapılandırılmasına dayanan bir teknikler koleksiyonudur. Bu kategori, 1980'lerin sonlarına kadar yapay zeka araştırmalarının paradigmasıydı ve yaygın olarak eski moda yapay zeka (GOFAI - Good old fashioned artificial intelligence)[87] olarak biliniyordu. Yapay zeka, olası sonuçların sınırlı olduğu, hesaplama gücünün az olduğu sorunları çözmek için hâlâ kullanılıyor. Bununla birlikte, sorunların karmaşık olma eğiliminde olduğu, her zaman tam olarak anlaşılmadığı ve birçok açıklayıcı değişkene sahip olduğu sağlık hizmetlerinde, sınırlı sayıda kurala dayalı bir model oluşturmak son derece zordur[88].

Makine öğrenimi (MÖ), ilk kez 1952'de Arthur Samuel tarafından ifade edilen bir terimdir ve mevcut paradigmadır. MÖ ile sembolik yapay zeka arasındaki temel fark, MÖ'de modellerin bir insan tarafından oluşturulan bir dizi kural yerine örneklerden öğrenmesidir[89]. Makineler, istatistiksel ve olasılık araçlarının bir karışımını kullanarak önceki modellerden öğrenebilir ve yeni veriler sunulduğunda eylemlerini geliştirebilir. Bu tahminler, yeni kalıpların belirlenmesi veya yeni verilerin sınıflandırılması şeklinde olabilir. MÖ, algoritmanın öğrenme türüne ve seçilen sonuca bağlı olarak üç türe ayrılabilir: Denetimli öğrenme (bilinen bir sonuca dayalı olarak sınıflandırma veya tahmin için kullanılır), denetimsiz öğrenme (bilinmeyen sonuçları olan gizli kalıpları ve yapıları bulma), ve takviyeli öğrenme (makine, amaçlanan ödülü en üst düzeye çıkaran önceki versiyonlara dayalı değiştirilmiş bir algoritma geliştirir) [90].

Derin öğrenme (DÖ), makinenin belirli bir girişin belirli özelliklerini kendisinin hesapladığı bir MÖ alt alanıdır. DÖ'nün öncüsü, ilk olarak 1900'lerde geliştirilen bir yapay sinir ağıdır (YSA). Hesaplama teknolojisi ve gücünün katlanarak artmasıyla birlikte araştırmacılar, daha karmaşık

pratik sorunları çözmek için daha karmaşık ve "daha derin" sinir ağları tasarladılar. Sinir ağı “derin öğrenme” olarak bilinmeye başlandı[91].

2.8.1 Yapay zeka eğitim verilerinde veri fazlalığı

Yapay zeka (AI) eğitim verilerinde aynı verinin tekrarlanması durumuna "data redundancy" (veri fazlalığı) veya "data duplication" (veri tekrarı) denir. Bu durum, çeşitli sakıncalara neden olabilir ve belirli çözümler gerektirir.

2.8.1.1 Sakıncaları

Overfitting (Aşırı Uyum): Model, eğitildiği verilere aşırı uyum sağladığında, yeni ve görülmemiş verilerle karşılaştığında iyi performans gösteremez. Bu durum, modelin genelleme yeteneğini zayıflatır[92].

Eğitim Süresinin Uzaması: Veri seti gereksiz yere büyüdüğünde, eğitim süresi uzar ve daha fazla hesaplama kaynağı gerektirir. Bu, eğitim sürecinin maliyetini ve zamanını artırır[93].

Bias (Önyargı): Veri setinde belirli örneklerin tekrarlanması, modelin bu örneklerle aşırı önem vermesine neden olabilir. Bu durum, modelin önyargılı öğrenmesine ve diğer önemli verileri göz ardı etmesine yol açar[94].

Verimsizlik: Gereksiz veri depolama ve işlem yükü nedeniyle kaynaklar verimsiz kullanılır. Bu durum, hem hafıza kullanımını, hem de işlemci yükünü gereksiz yere artırır[95].

2.8.1.2 Çözüm Yolları

Veri Temizliği: Veri setini temizleyerek tekrarlanan verileri çıkarmak, daha dengeli ve etkili bir veri seti oluşturur. Bu, modelin genelleme yeteneğini artırır.

Veri Artırma (Data Augmentation): Mevcut verileri manipüle ederek (örneğin, döndürme, ölçekleme, çevirme) yeni veriler oluşturmak, modelin daha çeşitli verilere maruz kalmasını sağlar. Bu yöntem, özellikle görüntü işleme alanında yaygın olarak kullanılır[96].


Cross-Validation (Çapraz Doğrulama): Modelin performansını değerlendirmek ve overfitting'i önlemek için çapraz doğrulama yöntemlerini kullanmak, modelin genelleme yeteneğini artırır.

Regülerizasyon Teknikleri: L1 ve L2 regülerizasyon gibi teknikler, modelin ağırlıklarını cezalandırarak aşırı uyumu önler. Bu teknikler, modelin daha genel kalmasını sağlar ve overfitting'i azaltır.

Bu adımlar, eğitim verilerinde tekrarlanan verilerin neden olabileceği olumsuz etkileri azaltmak ve daha etkili modeller oluşturmak için önemlidir[96].

2.8.2 Makine öğrenimi


Makine öğrenimi yapay zekanın önemli bir alt başlığıdır ve bir veri kümesine dayalı sonuçları tahmin etmek için algoritmalara dayanan yapay zekanın bir parçasıdır. Makine öğreniminin amacı, sorunları insan girdisi olmadan çözebilmeleri için makinelerin verilerden öğrenmesini kolaylaştırmaktır[97]. Makine öğrenimindeki son ilerlemeler, insan düzeyinde semantik anlayış ve bilgi çıkarma gibi görünen bir şeye ve bazen de soyut kalıpları insan uzmanlardan daha fazla doğrulukla tespit etme becerisine ulaşmıştır[98].



Şekil 2.3: Derin öğrenme metodunun diğer yapay zeka teknikleri ile olan ilişkisi[87]

2.8.3 Yapay sinir ağı

Yapay zekayı anlamak için makine öğrenmesi, derin öğrenme ve sinir ağı gibi terimlere aşina olmak gerekir. Son yirmi yıldaki yayın hacmine bakıldığında, YSA tıpta en popüler YZ tekniğidir[99]. YSA'lar, biyolojik sinir sisteminden ilham alan hesaplamalı analitik araçlardır. Paralel işlem yapabilen, "nöronlar" yüksek düzeyde birbirine bağlı bilgisayar işlemcilerindeki ağı oluştururlar. Bu nöronların amacı, insan beyni gibi işlev gören sinir ağı oluşturmaktır[98].



Şekil 2.4: Biyolojik sinir hücresi ve yapay sinir ağı[100]

YSA, birbirine bağlı yapay nöronlardan oluşur. Her yapay nöron, ağırlıklı kanıt toplamına dayalı olarak bir karar sinyali veren basit bir sınıflandırıcı modeli uygular. YSA'yı oluşturmak için bu temel hesaplama birimlerinden yüzlercesi bir araya getirilir. Ağın ağırlıkları, giriş sinyali çiftlerinin ve istenen çıktı kararlarının sunulduğu, beynin belirli görevleri başarmayı öğrenmek için harici duyuşal uyarılara dayandığı durumu taklit eden geri yayılım gibi bir öğrenme algoritması tarafından eğitilir[101].

YSA nöronuna n tane veri girişi olmaktadır ($x_1, x_2, x_3, \dots, x_n$). Bu girdilere karşılık olarak ağırlık değerleri ($w_1, w_2, w_3 \dots w_N$) ağ üzerindeki etki değerlerdir. Tüm girdiler ağırlık değerleri ile

çarpılarak transfer fonksiyonunda birleştirilerek bias değeri de (b) katıldıktan sonra aktivasyon fonksiyonundan geçirilmektedir[102].

Aktivasyon fonksiyonundan bulunan değeri çıkış değeri olarak kabul edilir. Bir yapay sinir hücresinin birden fazla girdisi olmasına karşın bir tane çıktı değeri vardır. YSA hesaplama modellerini insan beyni sinapslarının ve nörunun mimarisini öğrenerek hesaplama birimlerini modeller[101]. YSA'nın hesaplama gücü, bağlantıların ağırlıkların güncellenmesini olanak sağlayan eğitim veri setlerinin miktarına ve kalitesine bağlıdır[103, 104]. Ağırlıklar veri setleri arasında en elverişli olan değeri bulmaya çalışır ve böylece YSA'nın eğitimi gerçekleşir[105].

Yapay Sinir Ağı Özellikleri

Yapay sinir ağlarının çeşitli temel özellikleri vardır:

- Doğrusal Olmama
- Paralel Çalışma
- Öğrenme
- Genelleme
- Hata Toleransı ve Esneklik
- Eksik Verilerle Çalışma
- Çok Sayıda Değişken ve Parametre Kullanma
- Uyarlanabilirlik

Yapay Sinir Ağları uygulamaları genellikle tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme benzeri işlemlerde kullanılmaktadır.

Tahmin: Bu amaçla kullanılan yapay sinir ağları, girdi değerlerinden çıktıyı tahmin etmek olarak tanımlanır.

Sınıflandırma: Bu amaçla kullanılan yapay sinir ağları, girdi değerlerini sınıflama görevini yaparlar.

Veri İlişkilendirme: Bu amaçla kullanılan yapay sinir ağları, eksik olan bilgileri öğrendiği bilgiler ile tamamlar.

Veri Yorumlama: Bu amaçla kullanılan yapay sinir ağları, girdileri çözümler. Bir olay hakkında oluşturulan örneklerden elde edilen ve eğitim sonucu ortaya çıkan bilgileri kullanarak yeni olayların yorumlanmasına olanak sağlar.

Veri Filtreleme: Bu amaçla eğitilen ağlar, birden fazla veri arasından uygun olan verileri belirleyerek görevlerini tamamlarlar[106].


2.8.4 Yapay sinir ağı mimarileri

Yapay sinir ağının eğitilmesi için kullanılan algoritmaya bağlı olarak sınıflandırılan yapay sinir ağı sistemleri yapay sinir ağı mimarisi olarak da adlandırılır. Çeşitli sinir ağı mimarilerinden en çok kullanılanları şunlardır:

- Tek katmanlı algılayıcılar
- Çok katmanlı algılayıcılar
- İleri beslemeli yapay sinir ağları
- Geri beslemeli yapay sinir ağları

2.8.4.1 Tek katmanlı algılayıcılar


Tek katmanlı ağlar yalnızca girdi ve çıktıdan oluşmaktadır. Bu algılayıcılarda çıktı fonksiyonu doğrusaldır ve 1 veya -1 değerlerini almaktadır.



Şekil 2.5: Tek Katmanlı algılayıcıların model örneği[100]

2.8.4.2 Çok katmanlı algılayıcılar

Çok katmanlı algılayıcılar, girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşur (Şekil) [107]. Katman ve nöron sayıları, çözülecek probleme bağlı olarak değişir. Bir yapay sinir ağı modellemesi yapılırken, kullanılan veri seti genellikle iki veya üç parçaya ayrılır. Bu ayırım, iyi bir genelleme sağlamak amacıyla yapılır. Derin sinir ağı algoritmalarında, veri seti genellikle eğitim ve test olarak ikiye ayrılır. Eğitim veri seti, sinir ağındaki ağırlıkların tahminlerini hesaplamak için kullanılırken, test veri seti ise modelden gizlenen verilerle elde edilen ağırlık değerlerinin doğruluğunu test etmek için kullanılır [108].



Şekil 2.6: Çok katmanlı algılayıcıların şematik gösterim örneği [107]

2.8.4.3 İleri beslemeli yapay sinir ağları

Bilginin giriş nöronlarından çıkış nöronlarına tek yönlü aktarıldığı sinir ağı mimarileridir. Veri, girişte alındıktan sonra her katmanda işlenir ve bir sonraki katmana iletilir, ancak önceki katmanlara geri dönüş yapılmaz [109].

2.8.4.4 Geri beslemeli yapay sinir ağları


Geri beslemeli sinir ağlarında bağlantılar, bilginin hem ileri hem de geri yönde yayılmasına izin verir. Yani, bir nöronun çıktısı sadece sonraki katmana değil, aynı zamanda önceki katmana veya kendi katmanındaki herhangi bir nörona girdi olarak verilebilir [109]. Bu, doğrusal olmayan dinamik bir davranıştır. Geri besleme özelliğini kazandıran bağlantıların düzenlenişi, aynı yapay sinir ağıyla farklı davranış ve yapılarda geri beslemeli yapay sinir ağları elde edilmesini sağlar [100].

2.8.5 Derin öğrenme ve derin evriřimli sinir aęları

Derin öğrenme, yapay sinir aęlarının kullanıldığı çoklu işleme katmanlarından oluşan makine öğreniminin bir bileşenidir. Girdi verilerini analiz etmek için derin bir sinir aęında farklı hesaplama katmanlarına sahip aęı kullanır. Derin öğrenmenin amacı, özellik algılamayı iyileştirmek için kalıpları otomatik olarak tanımlayan bir sinir aęı oluşturmaktır. Soyutlanmış filtre katmanından özellikler toplanır, öncelikle büyük ve karmaşık verileri işlemek için kullanılırlar[86].

Derin öğrenme modelleri giriş bilgisi olarak bölümlere ayrılmış nesnelerden hesaplanan özellikler yerine doğrudan görüntülerdeki piksel değerlerini kullanır.

MÖ modellerinin aksine, yapılan eğitim sonucunda, sadece ham veriyi işleyerek çıkarım yapabilme özelliğine sahiptir. Genellikle belirsiz veya karmaşık nesneler için meydana gelen hatalı özellik hesaplaması ve segmentasyonun neden olduğu hataları önleyebilmektedir [110].




Şekil 2.7: a) Makine öğrenmesi modeli ve b) Derin öğrenme modeli [110]

Derin öğrenme yapay zekanın en yeni alt kümesidir, temel olarak girdiler ve çıktılar arasındaki evrimsel sinir ağları, katman sayısı bakımından önceki YSA'lerden farklıdır. Bu katmanlar sayesinde girdilerden veri toplar[101, 111]. Bu fazla sayıda katmandan oluşan ağ yapılarına derin evrimsel sinir ağları (DESA) adı verilmektedir.

Katmanlarından çeşitli birden fazla özelliği çıkarabilen bu yapılar, asıl olarak daha büyük ve karmaşık görüntüleri işlemek için kullanılmaktadır[103]. Çeşitli görevleri yapacak olan bu katmanlar sağlık alanı ile ilgili görüntülerde; hastalık teşhis etme, sınıflandırma, nesne tanımlama gibi işlemleri gerçekleştirebilirler[102].

Derin evrişimsel sinir ağı (DESA), evrişim katmanı, havuzlama katmanı, aktivasyon fonksiyonu ve çıktı katmanı olmak üzere dört ana katmandan oluşur[112]. Bu yapının temel amacı, görüntülerin önemli özelliklerini ortaya çıkararak gereksiz bilgilerin yapay sinir ağına girmesini engellemektir. Böylece sistemin hız ve doğruluk oranı artırılır. Evrişimsel sinir ağı (ESA) mimarisi, toplanan bilgileri uçtan uca öğrenme kapasitesine sahiptir. Büyük ölçekli verileri değerlendirme yeteneği, bu modelin önemli avantajlarından biridir. Ancak, eğitim süresinin uzun sürmesi ve eğitim sürecinde yerel çözümlere takılma olasılığı, evrişimsel sinir ağlarının dezavantajları arasında yer alır[113].



Şekil 2.8: DESA mimarisi modeli[112]

2.8.5.1 Giriş katmanı

DESA'ya ham olarak verilen giriş görüntüsünü belirtmektedir.

2.8.5.2 Evrişim katman

Evrişim katmanı, girdiyi önemli özellikleri çıkararak yoğunlaştırır ve çeşitli özellik dedektörlerine yanıt olarak özellik haritaları oluşturur. İlk evrişim katmanında, kenar gibi basit özellikler nöronlar tarafından filtrelendirilir. Nöronlar, evrişim katmanlarında bilgileri toplayarak görüntünün daha geniş bir resmini elde etmeyi öğrenir, böylece yüksek düzeyde bir tespit sağlar[114].

2.8.5.3 Havuzlama katmanı

Havuzlama veya alt örnekleme, genellikle birkaç evrişim katmanı arasında yer alan çeşitli işlem türlerini içerir. Bu işlem, yerel verileri bir havuzlama penceresiyle yoğunlaştırarak ve böylece

veri boyutunu azaltarak önemli özellikleri vurgulamayı amaçlar. Havuzlama, aynı zamanda hesaplama yükünü azaltarak işlemci kaynaklarını daha verimli kullanmaya olanak tanır[114].

2.8.5.4 Tam bağlı katmanlar

Genellikle havuzlama katmanı ardından gelen bu katman, kendinden önce gelen bütün katmanın tüm alanlarına bağlıdır bu sebeple tam bağlantılı katman denilmektedir[115].

2.8.5.5 Sınıflandırma katmanı

Bu katman tam bağlantılı katmandan sonra gelmektedir. Derin öğrenme mimarilerinin bu katmanında sınıflandırma işlemi yapılmaktadır. Bu katmandaki çıkış değeri, sınıflandırması yapılacak olan nesne sayısına eşittir[115].

2.8.6 Evrişimli sinir ağı modelleri

Literatürde yer alan evrişimli sinir ağı modellerine LeNet-5, AlexNet, VGG-16, VGG-19, ResNet, GoogleNet örnek olarak verilebilir[116].

2.8.6.1 AlexNet

AlexNet birçok derin öğrenme modelini meydana getiren mimari olarak tanımlanmaktadır. İlk olarak 2012 yılında tanıtımı yapılan AlexNet 2012'ye kadar tanımlanmış yapay sinir ağı modellerine büyük bir yenilik sunmuştur. AlexNet, önceki modellere göre daha fazla katmana sahiptir. Bu da daha fazla öğrenme derinliği anlamına gelmektedir. Görüntü sınıflandırmasında oldukça yaygın kullanılan bir mimaridir[117].

2.8.6.2 VGGNet

2014 yılında Oxford Üniversitesi'ndeki Visual Geometry Group (VGG) tarafından geliştirilen model; görüntü sınıflandırma, nesne tespiti ve nesne lokalizasyonu gibi görsel görevler için kullanılmaktadır. VGG, 16 ve 19 katmanlı olmak üzere iki farklı derinlikte mimari sunar[118]. Bu modeller VGG-16 ve VGG-19 olarak adlandırılır. VGGNet kullanımı kolaydır ve bu modeller çeşitli görevler için transfer öğrenme yöntemi olarak etkili bir şekilde kullanılabilir[119].

VGG-16 modeli, evrişimli katmanlarda küçük boyutlu filtreler (3x3) kullanır. Ardışık ikili veya üçlü evrişim katmanlarından sonra bir ortaklama katmanı bulunur. Bu havuzlama katmanı, VGG-

16'yı diğer modellerden ayıran belirgin bir özelliktir. VGG-16 modeli yaklaşık 138 milyon parametreye sahiptir[120].

2.8.6.3 ResNet

Microsoft Research tarafından 2015 yılında geliştirilen ResNet (Residual Network), evrimsel sinir ağı mimarisini temel alır ve çok sayıda katman içerir. Bu özellikleri sayesinde karmaşık özellikleri daha etkili bir şekilde yakalamayı amaçlar. ResNet, ImageNet veri kümesindeki sınıflandırma görevinde büyük başarı elde etmiştir. Modelin diğerlerinden ayrılan önemli bir özelliği, geriye doğru gradyan akışını kolaylaştıran ve daha derin ağlarda öğrenmeyi iyileştiren "skip connections" adlı bağlantılara sahip olmasıdır[121].

2.8.6.4 GoogleNet

Google tarafından 2014 yılında geliştirilen GoogleNet, ImageNet Visual Recognition Challenge (ILSVRC) yarışmasına katılmak amacıyla tasarlanmıştır. Bu model, evrimsel sinir ağı mimarisi kullanır ve inception adı verilen modüllere sahiptir. Inception modülleri, derin öğrenmenin popülerliğini artıran yeni bir yaklaşım sunmuştur[122].

2.8.7 Tekrarlayan sinir ağları (RNN)

Ağın yapısı, standart çok katmanlı bir algılayıcıninkine benzerdir[107]. Farkı ise bir zaman gecikmesiyle ilişkili gizli birimler arasındaki bağlantılara izin vermesidir. Bu bağlantılar vasıtasıyla model geçmişle ilgili bilgileri tutabilir ve verilerde birbirinden çok uzak olan olaylar arasındaki zamansal korelasyonları keşfedebilir[123].

2.8.8 Uzun kısa vadeli hafıza ağları (LSTM)

Uzun Kısa Vadeli Hafıza (Long Short-Term Memory - LSTM) sinir ağı, ilk olarak 1997 yılında Hochreiter ve Schmidhuber tarafından tanıtılmıştır (Şekil)[107]. Bu ağ, geliştirilmiş bir RNN (Recurrent Neural Network) türüdür ve RNN'lerde gözlemlenen bazı zayıflıkları gidermek amacıyla ortaya çıkmıştır.

Özellikle standart RNN modellerinde karşılaşılan kısa vadeli bellek sorununu çözmeyi hedeflemiştir. LSTM ağları, uzun süreli bağımlılıkları koruyabilme yetenekleri sayesinde son zamanlarda sıkça tercih edilen bir mimari haline gelmişlerdir[124].

2.8.9 Derin inanç ağıları (DBN)

Derin İnanç Ağları (DBN), sınırlı Boltzmann makineleri mimarisiyle otokodlayıcıların birleşiminden oluşan yapıları ifade eder. Bu ağlar değişken giriş ve çıkış boyutlarına sahip olabilirler. Katmanlar, kendilerinden önceki ve sonraki katmanlarla bağlantılıdır aynı zamanda düğümler arasında yatay iletişim bulunmamaktadır[107]. Son katmanda, denetimsiz öğrenme ile kümeleme ve softmax katmanı ile sınıflandırma gibi işlemler gerçekleştirilebilir. Derin İnanç Ağları özellikle görüntü tanıma uygulamalarında yaygın olarak kullanılmaktadır[107].

2.8.10 Derin öğrenme kütüphaneleri

Derin öğrenme mimarilerinin eğitimi için birçok yazılım ve yazılım kütüphanesi geliştirilmiştir. Bu kütüphanelerin çoğu açık kaynaklıdır ve sürekli olarak farklı kullanıcılar tarafından geliştirilmektedir. Kullanılacak kütüphane, çalışılacak konuya göre seçilmelidir çünkü her bir kütüphane farklı işlevlere sahiptir.

Güncel derin öğrenme yazılım kütüphaneleri arasında şunlar bulunmaktadır: Theano, TensorFlow, Caffe, Keras, Mxnet, Pylearn2, Lasagne, Torch, Covnetjs, Sci-Kit Learn, Deeplearning4j, Apache Spark. Bu kütüphaneler genellikle “Python” programlama diliyle kullanılmaktadır ve derin öğrenme modellerinin eğitimi, uygulanması ve değerlendirilmesi için çeşitli işlevler sunarlar[120].


2.8.11 Görüntü işleme

Görüntü, gerçek yaşamdaki üç boyutlu nesnelerin basit bir iki değişkenli fonksiyonu olarak tanımlanabilir. Başka bir deyişle, üç boyutlu görünümün iki boyutlu bir haritası olarak da ifade edilebilir[125].

Görüntü işleme; gerçek dünyadaki nesnelerin resim haline getirilmesi, ardından bu resimlerin özelliklerinin ve niteliklerinin değiştirilmesi işlemidir[126]. Bu işlemler, görüntüleri yorumlamak ve özel görüntüleme araçları için daha uygun hale getirmek amacıyla yapılır. Örneğin; bulanık veya düşük kaliteli resimlerin iyileştirilmesi, görüntü üzerindeki nesnelerin sınırlarının belirlenmesi, gürültü olarak adlandırılan rastgele hataların ve gerektiğinde istenmeyen ayrıntıların kaldırılması gibi işlemler görüntü işleme teknikleriyle mümkün olur[127].

Bir görüntünün işlenebilmesi ve bilgisayar ortamında kullanılabilmesi için önce sayısallaştırılması gerekmektedir. Sayısallaştırma, resim içindeki her renk için sayısal bir değer atanması işlemidir[128]. Bu süreçte fiziksel görüntünün her noktası için tanımlayıcı sayısal değerler bulunur. Görüntü içeriği, yatay ve dikey matrislerden oluşur. Her matrisin kesişim noktası bir pikseli temsil eder. Pikseller, dijital bir görüntüdeki en küçük noktalar olarak adlandırılır.

Görüntüdeki toplam piksel sayısı, görüntünün çözünürlüğünü belirtir. Çözünürlük, dijital görüntü matrisinin satır sayısı ile sütun sayısının çarpımıdır. Çözünürlük ne kadar düşükse, görüntü netliği de o kadar az olur[125].



Şekil 2.9: Piksel ifadesinin şematik gösterimi[125]

2.8.12 Görüntü işleme teknikleri

Elde edilen görüntü bilgisi, çeşitli görüntü işleme teknikleri kullanılarak istenilen formata dönüştürülebilir. Bu işlem, görüntü üzerinde çeşitli dönüşümler ve işlemler yaparak görüntünün belirli özelliklerini veya yapılarını değiştirmeyi içerir.

Örneğin:

Boyutlandırma ve ölçeklendirme: Görüntüyü istenilen boyuta ve ölçeklere getirme işlemi. Örneğin, bir görüntüyü küçültmek veya büyütmek.

Renk dönüşümleri: Görüntünün renk uzayını değiştirme işlemi.

Örneğin, RGB renk uzayından HSV'ye veya gri ölçekliye dönüşüm yapma.

Filtreleme ve düzeltme: Görüntü üzerinde gürültüyü azaltma veya keskinleştirme gibi işlemler. Örneğin, Gaussian filtre kullanarak yumuşatma yapma veya kenar algılama işlemleri.

Morfolojik işlemler: Görüntü üzerinde şekil analizi yaparak, nesnelerin büyüklüğünü değiştirme veya şeklini düzeltme işlemleri.

Segmentasyon: Görüntüyü belli bölgelere ayırma işlemi.

Örneğin, nesne tanıma veya tespit için görüntüyü farklı bölgelere ayırma.

Yeniden yapılandırma ve yeniden biçimlendirme: Görüntüyü belirli bir şablona veya yapıya göre yeniden yapılandırma işlemi.

Örneğin, bir görüntüyü kullanıcı arayüzü için uygun hale getirme.

Bu işlemler, elde edilen görüntü bilgisini istenilen hale getirmek veya daha iyi analiz veya sunum yapabilmek için kullanılır. Her bir işlem, görüntünün özelliklerini değiştirebilir veya iyileştirebilir, böylece belirli bir amaç için daha uygun hale getirilebilir[129].

2.9 Diş Hekimliğinde Yapay Zeka

Günümüzde yapay zeka (YZ), sağlık sektöründe önemli bir dönüşüm sağlamakta ve diş hekimliği pratiğinde de etkili bir şekilde kullanılmaktadır. Yapay zeka teknolojileri, diş hekimlerine tanı koyma, tedavi planlama, hastaları takip etme ve eğitim gibi birçok alanda yardımcı olmaktadır.

Gelişmiş görüntü işleme algoritmaları ve derin öğrenme teknikleri sayesinde, diş röntgenleri ve tomografileri hızlı bir şekilde analiz edilebilir. Yapay zeka sistemleri; kaviteler, diş eti hastalıkları, çürükler ve diğer dental sorunları tespit etmek için kullanılabilir. Bu sayede; erken teşhis ve doğru tedavi planlaması yapılabilir, hastaların sağlık durumu daha hızlı değerlendirilebilir.

YZ, diş hekimlerine tedavi planlama sürecinde rehberlik eder. Örneğin, hasta verilerini analiz ederek kişiselleştirilmiş tedavi önerileri sunabilir. Yapay zeka destekli sistemler, hastanın diş yapısını ve sağlık geçmişini dikkate alarak en uygun tedavi seçeneklerini önerir. Bu, tedavi sürecinin daha etkili ve hasta odaklı olmasını sağlar.

Yapay zeka, hastaların tedavi süreçlerini izlemek ve bakımını sağlamak için de kullanılır. Örneğin; diş protezlerinin takibi, implantların durumu veya ortodontik tedavilerin ilerlemesi gibi alanlarda yapay zeka sistemleri kullanılabilir. Bu sistemler, hastaların sağlık durumunu sürekli olarak değerlendirir ve gerekirse diş hekimlerini uyarır.

Diş hekimliği eğitiminde ve araştırmalarında yapay zeka büyük bir rol oynamaktadır. Eğitim programlarına entegre edilen yapay zeka simülasyonları, öğrencilere pratik deneyim kazandırır ve tedavi planlaması konularında eğitim sağlar. Ayrıca, yapay zeka tabanlı araştırmalar; yeni tedavi yöntemlerinin geliştirilmesine ve mevcut tedavi protokollerinin iyileştirilmesine olanak tanır.

Son yıllarda yapay zekanın tıpta kullanımı ve hastalıkların tanı ve tedavisi için faydalı olmuştur. Kılıç ve arkadaşları Yapmış oldukları bir çalışmada mobil uygulama üzerinden yüklenen hasta fotoğraflarını yapay zeka kullanarak ortodontik teşhis amaçlı kullanılabileceğini ve böylece yetersiz hizmet alan topluluklarda ortodontik bakıma erişimin kolay olacağını göstermişlerdir[130].

Temporomandibuler eklem osteoartritinin ve osteoporozunun sınıflandırılması, CAD/CAM teknolojisi ile üretilen kronların diş üzerinden ayrılma olasılıklarının tahmini, çene lezyonlarının ve periodontal kemik kayıplarının otomatik olarak tespiti ve sınıflandırılması, oral kanser hastalarının tahmini yaşam sürelerinin hesaplanması, diş çürüklerinin ve osteoporozların tespiti gibi alanlarda yapay zeka algoritmaları kullanılmıştır [131-137].

Ayrıca, lateral sefalometrik radyografilerde anatomik yapıları otomatik olarak algılayabilen programlar geliştirilmiştir. Anatomik noktaların otomatik olarak tespitine dair ilk çalışma, 1986 yılında Levy-Mandel ve arkadaşları tarafından yapılmıştır[138]. Daha sonraları birçok araştırmacı, görüntü eşleme ve makine öğrenmesi yöntemleriyle anatomik noktaların otomatik olarak tespitini sağlamak üzerine çalışmıştır[139].

YZ algoritmasına sahip programlar, makine öğrenmesini kullanarak, görüntüler üzerinde tanısal ve analitik sonuçlar içeren sefalometrik analizler yapabilmektedir. Derin öğrenme algoritması ile ilgili çalışmalar, yapay zekanın sefalometrik radyografiler üzerinde anatomik noktaları doğru olarak tespit ettiğini göstermiştir[140, 141].

2.10 Otomatik Sefalometrik Analiz ve Yapay Zeka

Tamamen el ile işaretlenen sefalometrik analizden otomatik sefalometrik analize geçiş, analiz sırasında meydana gelen hataları ve harcanan süreyi azaltarak analizdeki tanısal değerleri iyileştirmeyi amaçlamaktadır[142]. Sefalometrik analizdeki hatalar genellikle çizim sırasında, anatomik noktaların tespitinde veya ölçüm sırasında meydana gelen sistemik hatalardır[35, 36, 66]. Bilgisayarlı sefalometrik analiz programları, ölçüm sırasında meydana gelen mekanik hataları ortadan kaldırır, ancak anatomik noktaların belirlenmesindeki tutarsızlık, hem bilgisayar destekli dijital sefalometrik analizde hem de konvansiyonel sefalometrik analizde hala önemli bir hata kaynağıdır[35, 36].

Anatomik noktaların belirlenmesi sırasında meydana gelen hataların, ölçüm sırasında meydana gelen hatalara oranla 5 kat daha fazla olduğu belirtilmiş olsa da, her iki yöntem de öznelliğe açıktır[143, 144]. Bilgisayar destekli sefalometrik analiz, konvansiyonel yöntem kadar olmasa da zaman alıcı bir yöntemdir[142]. Bu nedenle; analizi gerçekleştirmek için gereken süreyi kısaltmak, anatomik noktaların daha doğru belirlenmesini sağlamak ve araştırmacı/klinisyen kaynaklı hataları azaltmak amacıyla sefalometrik analizi otomatikleştirme girişimleri olmuştur[145].

Otomatik bir analizde, sefalometrik radyografi bilgisayar tarafından saklanır ve yazılım tarafından yüklenir. Yazılım daha sonra anatomik noktaları otomatik olarak işaretler ve ölçümleri gerçekleştirir.

Ölçüm işlemlerinin bilgisayar destekli sefalometrik analiz yöntemlerinde neredeyse hatasız yapıldığı göz önüne alındığında, otomatik analizdeki en önemli unsur anatomik noktaların tespitidir[142].

Leonardi ve arkadaşları sefalogramların otomatik olarak işaretlenmesi için kullanılan teknikler üzerine bir sistematik inceleme yapmışlardır. İncelemelerinde, otomatik referans noktası tespitindeki hataların manuel yerleştirmeden daha fazla olduğunu ve otomatik izlenen sefalometrik izlemelerin klinik kullanım için yeterince doğru olmadığını bulmuşlardır[142].

Öte yandan, bazı çalışmalar tam otomatik sefalometrik yazılımların güvenilir olduğunu bulmuştur. Örneğin, Lindner ve arkadaşları, deneyimli ortodontistlere benzer ve %84,7 doğrulukla referans noktası belirleyen yapay zeka sistemini geliştirmişlerdir[146]. Ayrıca, Hwang

ve arkadaşları You-Only-Look-Once versiyon 3 (YOLOv3) adlı otomatik referans noktası tespit sistemini manuel tespit ile karşılaştırmış ve YOLOv3'ün ortodontistler tarafından işaretlenen noktalara yakın olduğunu bulmuşlardır[141]. Bulatova ve arkadaşları Ceppro DDH Inc yazılımını incelemiş ve yapay zekanın on altı noktanın on ikisini insan operatörlerden 2 mm'den az farkla doğru şekilde işaretlediğini bulmuşlardır[147]. Derin öğrenme modelleri ile çalışan tam otomatik sefalometrik analizler ham verileri işleyerek anatomik noktaların yerlerini tespit etmektedirler. YZ eğitim verilerinde benzer verinin tekrarlanması durumuna veri tekrarı denir. Bu durum aşırı uyum ve ön yargıya sebep olur[92, 94]. Derin öğrenme tabanlı sefalometrik analiz programlarına yüklenen sefalometrik görüntülerin büyük bir kısmının cerrahi ihtiyacı olmayan normal değerlere yakın hastalardan oluşmaktadır. Amerika Birleşik Devletleri'nde, ortognatik cerrahi ihtiyacı olan maloklüzyon veya yüz deformitesine sahip bireylerin oranı yaklaşık %2'dir[148]. Bütün veri havuzunda norm değerlerine yakın hastaların verileri ile eğitilmiş olan derin öğrenme sistemleri veri tekrarına oluşur[92, 94].

2.11 3B Görüntüleme Teknikler

2.11.1 Manyetik rezonans görüntüleme

İlk nükleer manyetik rezonans, 1940'larda keşfedildi ve otuz yıl sonra görüntüleme amacıyla önerildi. O zamandan beri, manyetik rezonans görüntüleme (MRG); tanısal klinik tıp ve biyomedikal araştırmalarda en güçlü tekniklerden biri haline geldi. Günümüzde MRG, öncelikle anatomik görüntüler üretmek için bir teknik olarak kullanılmaktadır. Ancak aynı zamanda hareket ve akış hakkında işlevsel bilgiler sunar. MRG yumuşak dokuyu ortaya çıkarırken detaylı morfoloji, manyetik rezonans spektroskopisi fiziksel - kimyasal durum hakkında bilgi sağlar ve in-vivo biyolojik araştırmalarda bir araç olarak kullanışlılığı açıkça ortaya konmuştur.[16]

Manyetik rezonans görüntüleme, diğer görüntüleme tekniklerinden farklı bir çalışma prensibine sahiptir. Örneğin BT, dokuların radyasyon ışınlarının absorbe edilme gücünü kullanırken, MRG doku içindeki su miktarlarını kullanır.

MRG'nin diğer görüntüleme tekniklerinden en büyük farkı, dokuların iyonize edici ışınlara maruz kalmamasıdır. İncelenmek istenen bölgeye radyo dalgaları gönderilir ve hidrojen kullanılarak dokulardaki farklılıkları belirlemek için görüntü elde edilir.[17]

Ortodontide MRG kullanımını sınırlayan faktörler, ekonomik maliyetin yanı sıra, görüntülenen dokularda çok sayıda hidrojen çekirdeğinin olması gerekliliğidir. Çünkü kemik, mine ve dentin gibi sert dokular az miktarda serbest hidrojen çekirdeğine sahiptir. Bu nedenle, bu güçlü tanı aracının ortodontide kullanımının temporomandibular eklemdaki kıkırdak bileşenlerinin görselleştirilmesiyle sınırlı olduğu iddia edilmiştir.[18]

Ancak son dönemde, erken yaş grubu hastalarda iyonize radyasyonu elimine etmek adına dental anomalilerin, gömülü dişlerin teşhisi ve ortodontik tedavi planlamasında MRG'nin güvenle kullanılabileceğini belirten çalışmalar vardır[149, 150].

2.11.2 Konik ışınlı bilgisayarlı tomografi

Koni ışını bilgisayarlı tomografi (KIBT), koni şeklindeki X-ışını demetini kullanarak iki boyutlu bir dedektöre yerleştirilmiş olan görüntü oluşturma tekniğidir. Kaynak dedektör sistemi, bir nesnenin etrafında bir dizi iki boyutlu görüntü üretmek için bir dönüş hareketi gerçekleştirir[151].

Konik ışınlı görüntülemenin katkıları, öncelikle anatomik olarak karmaşık bir alan içindeki yapıların ilişkisinin kesin olarak anlaşılmasına olanak sağlamasıdır. Ayrıca, düşük radyasyon alımı ve düşük görüntüleme maliyeti ile birlikte yüksek uzamsal kemik ve diş çözünürlüğü sunar.[20]

KIBT'nin avantajları olmasına rağmen, önemli dezavantajları da bulunmaktadır. Bu dezavantajların başında görüntü kalitesini zayıflatan artefaktlar gelmektedir. Artefaktlar, görüntülenen objeyle ilgisi olmayan hasarları ifade eder. Metal restoratif materyaller veya braketler gibi etkenlerden dolayı artefaktlar oluşabilir. Ayrıca, radyasyon dağılımına bağlı olarak görüntünün izlenmesini engelleyen dansite değişiklikleri (noise) de oluşabilir. KIBT'nin diğer önemli dezavantajı, yumuşak dokuların sınırlı bir şekilde görüntülenmesidir[151].

2.11.3 Bilgisayarlı tomografi

Görüntüleme teknikleri, genellikle ortodontide sınıflandırılan anatomik yapıların mevcut durumlarını değerlendirmek için kullanılır.

Bu nedenle, geleneksel radyografi yöntemleri, geçmiş yıllardan beri ortodonti kayıtlarının bir parçası haline gelmiştir. Kesitsel görüntüleme teknikleri, bilgisayarlı tomografi (BT) gibi, genellikle daha karmaşık sorunların çözümüne yardımcı olmak için kullanılır[19].

BT başlangıçta bir kafa tarayıcısı olarak tasarlanmış ve orofasiyal yapıların değerlendirilmesinde de kullanılmaktadır. Ancak, BT makinelerinin diş hekimliği için yüksek maliyetleri, geniş yer gereksinimi ve yüksek radyasyon maruziyeti gibi sınırlamaları bulunmaktadır. Bunlara rağmen yüksek görüntüleme kalitesi, minimum saçılma ve artefakt için BT hala rakipsizdir[20].

Radyologlar tarafından bilgisayarlı tomografi (BT) görüntülerinin değerlendirilmesinde Hounsfield birimi (HU), kullanılmaktadır. Hounsfield birimi (HU) bir radyo yoğunluk ölçüm birimidir. BT taramaları sırasında, dokunun içindeki radyasyon Emilimi veya azaltma katsayısı kullanılarak bir gri tonlama görüntüsü elde edilir. HU, bu radyo yoğunluk değerlerinin sayısal olarak ifadesidir.

Hounsfield ölçeğinde:

Saf suyun radyo yoğunluğu 0 HU olarak kabul edilir.

Havanın radyo yoğunluğu -1000 HU olarak kabul edilir.

Kemik gibi çok yoğun dokuların radyo yoğunluğu ise 1000 HU veya daha fazla olabilir.

KIBT ile karşılaştırıldığında temel üstünlükleri, yumuşak doku penceresinin ve hassas Hounsfield birimlerinin var olması, ayrıca çok daha düşük görüntü gürültüsüdür[151].

BT ve 3 boyutlu tekniklerin gelişmesiyle birlikte geleneksel görüntüleme yöntemlerinin yeniden değerlendirilmesi gerekmektedir. Bugün ortodonti literatüründe 2 boyutlu tanı yönteminin artık geçerliliğini yitirdiği ve gelecekte yalnızca olmasa da öncelikli olarak 3 boyutlu sefalometrinin olacağı iddiaları artmaktadır[152, 153]. Yeni görüntüleme tekniklerinin bulunması, daha düşük maliyetlerle ve radyasyonla 3 boyutlu görüntüleme yapılmasını sağlamaktadır[153, 154].

3 GEREÇ VE YÖNTEM

Çalışmamızın etik kurul onayı Bezmialem Vakıf Üniversitesi Klinik Araştırmalar Etik Kurulu'nun 06.09.2022 tarihli 2022/268 sayılı raporuyla alınmıştır.

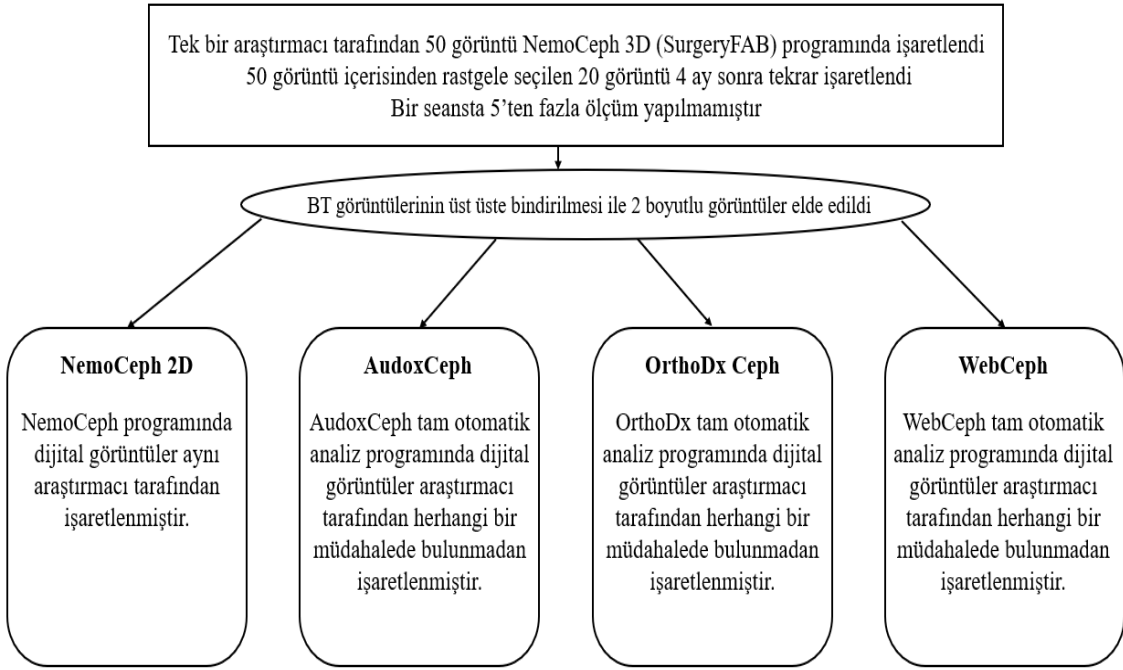
Literatürde benzer çalışmalara bakıldığında %95 güven düzeyinde %80 güç için ortalamalar arası fark 1.9, standart sapması 2.6 olarak alındığında minimum örneklem sayısı 43 olarak bulunmuştur. Bu çalışmada ise örneklemimiz data kaybı ihtimali göze alınarak 50 kişiden oluşmaktadır[139].

Bu çalışmaya Bezmialem Vakıf Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalına başvuran ve yapılan ortodontik analizlerin sonucuna göre ortognatik cerrahi ile tedavi edilecek hastalar dahil edilmiştir. Örneklem grubunda bulunan hastalardan ortognatik cerrahi öncesinde rutin olarak üç boyutlu BT alınmaktadır. BT(Philips, Ingenuity 128 Slice, Hollanda) görüntüleri Bezmialem Tıp Fakültesi Hastanesi Radyoloji Polikliniğinde bir tekniker tarafından standartlara uygun olarak 1 mm kesit aralığı ile alınmıştır. BT görüntüleri programlara yüklenmeden önce koordinatör tarafından rastgele numaralar verilerek randomize edilmiştir. Toplam 50 adet kayıt mevcuttur. Hastaların BT görüntülerindeki anatomik noktalar, NemoCeph 3D (SurgeryFAB) programında 3 boyutlu görüntülerin 2 boyutlu rekonstrüksiyonları tek bir araştırmacı tarafından işaretlenmiştir. Araştırmacının ölçüm içi güvenilirliğini tespit etmek amacıyla ilk işaretlemeden 4 ay sonra 50 hasta içerisinde rastgele seçilen 20 hastanın BT görüntülerindeki anatomik noktalar tekrar NemoCeph 3D (Surgery FAB) programında işaretlenmiştir.

BT'den elde edilen 3 boyutlu görüntüler birbirlerine paralel ışınlar ışınlar ile magnifikasyona sebep olmayan görüntüler elde edilmektedir[152]. BT'den elde edilen 3 boyutlu görüntülerin sagittal kesitlerinin üst üste bindirilmesi ile oluşturulan 2 boyutlu bir görüntü elde edilmiştir. Böylece küçük bir kaynaktan çıkan X ışınlarının birbirlerine paralel olmaması ve diverjan bir şekilde yayılması nedeniyle görüntüde meydana gelen genişleme önlenmiş olur[37]. Elde edilen 2 boyutlu sefalometrik görüntü öncelikle Nemoceph programında aynı araştırmacı tarafından işaretlenmiştir. Manuel işaretleme yapılmadan önce dijital sefalometrik röntgenler üzerindeki cetvel kullanılarak 30 mm'ye kalibre edilmiştir. Nemoceph (Nemotec, Madrid, Spain) programında oluşturulan 2 boyutlu sefalometrikler yapay zeka teknolojisi programı olan WebCeph (A.I. Web Based Orthodontic and Orthognatic Platform, Gyeonggi, South Korea), AudaxCeph

(Audax Ceph Orthodontic Software Suite Audax d.o.o. Ljubljana, Slovenia) ve OrthoDx (AI-Powered Orthodontic Imaging System, Phimentum) tarafından otomatik olarak çizilmiştir. Tam otomatik sefalometrik analiz programlarından WebCeph açık kaynak yazılım iken OrthoDx ve AudoxCeph açık kaynak yazılımlarından değildir.

Yapay zeka ile işaretlenen sefalometrik görüntülerde işaretleme sırasında 30mm'ye kalibrasyon yapılmıştır. Yapay zeka tarafından işaretlenen görüntüler üzerinde herhangi bir müdahale yapılmadan değerlendirilmiş ve bu sayede yapay zeka ile sefalometrik analiz yapan programların yeterliliği ölçülmüştür.



Şekil 3.1: BT görüntülerinde işlem aşamaları

Nemo Ceph bilgisayar destekli dijital sefalometrik analiz programı ölçümleri ortodonti alanında 3 yıl tecrübeli araştırmacının manuel işaretleme sonucu elde edilen analiz değerleri, yapay zeka algoritmasına sahip programların ölçümleri ile karşılaştırılmıştır.

3.1 Veri Kaynağı ve Hasta Grupları

Bu çalışmanın materyali Bezmialem Vakıf Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı'nda tedavi görmekte olan ortognatik cerrahi hastalarından ameliyat öncesi rutin olarak alınan BT'lerden oluşmaktadır. 50 hastadan toplanan BT'lerin tümünden elde edilen görüntüler 3 boyutlu ve 2 boyutlu görüntülerin sefalometrik işaretlemeleri yapılmıştır.

Çalışmaya 23 erkek ve 27 kadın hastanın BT görüntüleri dahil edilmiştir. Erkeklerin yaş ortalaması $25,30 \pm 5,83$, kadınların yaş ortalaması $23,96 \pm 5,61$ 'dir.

Bölümümüzde bu dönemde 167 hasta ameliyat olmuş ancak sadece 88 tanesinin verileri toplanabilmiştir. Bu yüksek sayıda veri kaybının sebepleri;

1-DVD kasetlerin kırılması/çizilmesi

2-Hastanın verileri kaybetmesi/teslim etmemesi

3-Bölümümüzde bulunan bulut sisteminde veri kaybı yaşanması

4-Çekilen bilgisayarlı tomografilerin yeterli görüntü alanına sahip olmaması

5- Çekilen bilgisayarlı tomografilerde yüksek seviyede saçılma olması

6- Çekilen bilgisayarlı tomografilerin yeterli görüntü kalitesine sahip olmaması

7-Radyografik görüntü kalitesinin çalışmada kullanılacak anatomik noktaların tespiti için yeterli olmaması olmuştur.


Veri kayıplarının ardından kalan 88 hastanın 16 tanesi dışlanma kriterleri sebebiyle çıkarılmış ve elimizde 72 hastanın verisi kalmıştır.

Dışlanma Kriterleri;

1-Hastanın onayı olmaması

2-Hastanın 2 boyutlu sefalometride yapay zekayı zorlayacak asimetri sahibi olması

Çalışmamızda planlanan 50 hastalık örneklem grubunu oluşturmak adına 72 hastalık veri grubuna 1'den 72'ye kadar rastgele numaralar verilmiştir. Verilen numaralar tarafsız bir araştırmacı tarafından rastgele seçilip 50 kişilik örneklem grubu tespit edilmiştir. Yapılan tüm işaretlemler ve çizimler rastgele seçilen örneklem grubu hastalarının tomografi görüntüleri üzerinden yapılmıştır.



Şekil 3.2: Hasta seçim aşamaları

3.2 Yöntem

50 adet Bezmialem Vakıf Üniversitesi Tıp Fakültesi Radyoloji Bölümünde çekilen BT görüntüsü NemoCeph programına yüklenmiştir. Nemoceph programında 3 boyutlu görüntüler kesitler halinde değerlendirilmiş ve fare kontrolündeki bir imleç ile belirlenen anatomik noktalar direkt olarak monitör üzerindeki görüntüde işaretlenmiştir. İşaretlenme aşamasında BT görüntüleri sagittal kesitlerde değerlendirilmiştir. Kafatasının her iki tarafında da bulunan anatomik noktalar için sol taraf seçilmiştir. Görüntülerin 3 boyutlu olarak incelenmesiyle tespit edilen ideal kesitte median kesitte kafatasında orta hatta bulunan anatomik noktalar işaretlenmiştir.

Yapılan işaretlemeden 4 ay sonra araştırmacının iç tutarlılığını tespit edebilme amacıyla, aynı araştırmacı tarafından rastgele 20 adet 3 boyutlu görüntü Nemoceph 3D (SurgeryFAB) programında bir kez daha yüklenmiş ve anatomik noktalar tekrar işaretlenmiştir.



Şekil 3.3: BT görüntülerinin üst üste bindirilmesiyle elde edilen lateral sefalometrik görüntü



Şekil 3.4: BT görüntülerinin sol sagittal kesitlerinde NemoCeph 3D programında sefalometrik çizim



Şekil 3.5: BT görüntülerinin ideal midsagittal kesitlerinde NemoCeph 3D programında sefalometrik çizimi


İşaretlenmiş dijital sefalometrik radyografiler JPEG formatında bilgisayara kaydedilmiştir.

Nemoceph programında BT'den elde edilen 3 boyutlu görüntülerin sagittal kesitlerinin üst üste bindirilmesiyle elde edilen iki boyutlu sefalometrik görüntüler kaydedilmiştir ve aynı programda iki boyutlu olarak işaretlenmiştir ayrıca Webceph, OrthoDx ve Audox programlarında yapay zeka ile otomatik olarak işaretlenmiştir. Yapay zeka ile işaretlenen noktalar üzerinde hiçbir değişiklik yapılmamıştır. Tüm işaretlemeler sırasında ilgili programlarda 30 mm'ye kalibrasyon yapılmıştır.


Araştırmacının işaretlemesi sonrasında, program tarafından gerçekleştirilen otomatik sefalometrik ölçüm değerleri Microsoft Excel programı kullanılarak listelenmiş ve bilgisayara kaydedilmiştir.




Şekil 3.6: Nemoceph programında BT'den elde edilen 3 boyutlu görüntülerin sagittal kesitlerinin üst üste bindirilmesiyle elde edilen görüntülerin NemoCeph programında sefalometrik çizimi




Şekil 3.7: Webceph tam otomatik sefalometrik analiz programında sefalometrik çizim




Şekil 3.8: Webceph tam otomatik sefalometrik analiz programında sefalometrik kalibrasyon




Şekil 3.9: Audox tam otomatik sefalometrik analiz programında sefalometrik çizim




Şekil 3.10: Audox tam otomatik sefalometrik analiz programında kalibrasyon



Şekil 3.11: OrthoDx tam otomatik analiz sefalometrik programında sefalometrik çizim



Şekil 3.12: OrthoDx tam otomatik analiz sefalometrik programında kalibrasyon



Şekil 3.13: OrthoDx tam otomatik sefalometrik analiz programında hatalı anatomik nokta işaretleme örneği

3.2.1 Çalışmada kullanılan sefalometrik noktalar

Çalışmamızda 6'sı yumuşak dokuda 19'u sert dokuda bulunmak üzere toplam 25 nokta kullanılmıştır.

1-S: Sella noktası. Sella tursikanın geometrik merkezidir.

2-N: Nasion noktası. Fronto-nazal suturen orta oksal düzlemle kesişen en ön noktası.

3-Or: Orbitale noktası. Göz çukurunun alt kenarının en derin noktasıdır.

4-ANS: Anterior nasal spina. Üst çene kemiğinin ön çıkıntısının en uç noktasıdır.

5-PNS: Posterior nasal spina. Üst çene kemiğinin arka çıkıntısının en uç noktasıdır.

6-A: Üst çene ön alveolar kemik girintisinin en derin noktasıdır.

7-U1 Apex: Üst çene ön kesici dişin kök ucu noktasıdır.

8-U1 Tip: Üst çene ön kesici dişin kron ucu noktasıdır.

9-L1 Apex: Alt çene ön kesici dişin kök ucu noktasıdır.

10-L1 Tip: Alt çene ön kesici dişin kök ucu noktasıdır.

11-B: Pogonion noktasının üzerindeki alt çene ön alveolar kemik girintisinin en derin noktasıdır.

12-Pog: Pogonion noktası. Alt çene kemiğinin en ön noktasıdır.

13-Gn: Gnathion noktası. Sert doku çene ucunun en ön ve alt noktasıdır.

14-Me: Menton noktası. Alt kesici dişlerin köklerinin lingual tarafını örten alveol kemiği görüntüsünün en arka çizgisini (kemiğin kompakt kısmı) aşağıya doğru takip ettiğimizde, bu çizginin mandibula alt kenarıyla birleştiği nokta, menton noktasıdır.

15-Go: Alt çene ramusunun arka kenarına çizilen teğet ile alt çenenin alt kenarına çizilen teğetin oluşturduğu açının açıortayının alt çene kemiği üzerindeki izdüşümüdür. Çift görüntü olduğu zaman ortalanır.

16-Po: Porion noktası. Kafa kemiği üzerindeki dış kulak deliğinin (meatus acusticus externus) üst kenarının orta noktasıdır.

17-Ar: Articulare noktası. Alt çene kemiğinin artiküler çıkıntısının (processus articularis ossis mandibularis) arka kenarı ile kafa kaidesi dış(alt) sınırının kesişme noktasıdır.

18-Ba: Basion noktası. Foramen occipitale magnum'un ön kenarının en ön noktasıdır.

19-Pt: Pterygomaksiller nokta. Fissura pterygomaxillaris'in en alt noktasıdır.

20-Prn: Pronasale noktası. Burnun en öndeki noktasıdır.


21-Sn: Subnasale noktası. Burun ve üst dudağın birleşme noktasıdır.

22-A': Yumuşak doku A noktası. Burun ve üst dudak arasındaki içbükey bölgenin en derin noktasıdır.

23-Ls: Üst dudağın en ön noktası.


24-Li: Alt dudağın en ön noktası

25-Pog': Yumuşak doku üzerinde çenenin en ön noktasıdır



Şekil 3.14: Çalışmada kullanılan sert doku noktaları

1. Nasion, 2. ANS, 3. PNS, 4. A, 5. U1 apex, 6. U1 tip, 7. L1 tip, 8. L1 apex, 9. B, 10. Pog, 11. Gn, 12.Me, 13. Go, 14. Ba., 15. Po, 16. Ar, 17. Pt, 18. S, 19.Or



Şekil 3.15: Çalışmada kullanılan yumuşak doku noktaları

1.Gl', 2.N', 3.Pr, 4. Sn, 5. A', 6. Ls, 7.Sts, 8. Sti, 9. Li, 10. B', 11. Pog', 12. Gn', 13. Me'

3.2.2 Çalışmada kullanılan sefalometrik ölçümler

Çalışmamızda 17 açısal, 15 çizgisel, 1 oransal olmak üzere toplam 33 sefalometrik ölçüm değerlendirilmiştir.

1-SNA°: S, N ve A noktaları arasında oluşan açıdır.

2-SNB°: S, N ve B noktaları arasında oluşan açıdır.

3-ANB°: A, N ve B noktaları arasında oluşan açıdır.

4-N-A: N noktasından FH (Frankfurt Horizontal: Po ve Or noktalarından geçen doğrudur) düzlemine indirilen dikmenin A noktasına olan doğrusal mesafedir.

5-N-Pog: N noktasından FH (Frankfurt Horizontal: Po ve Or noktalarından geçen doğrudur) düzlemine indirilen dikmenin Pog noktasına olan doğrusal mesafedir.

6- Wits (mm): A ve B noktalarının oklüzyon düzlemi (OD) üzerindeki izdüşümleri arasındaki mesafe.

7- Y Aksı Açısı: FH doğrusu ile S ve Gn noktalarından geçen doğru arasında oluşan açıdır.

8-SN/GoMe: Go ve Me noktalarından geçen doğru ile S ve N noktalarından geçen doğru arasında oluşan açıdır.

9-SN/PP: ANS ve PNS geçen doğru ile S ve N noktalarından geçen doğru arasında oluşan açıdır.

10-SN/GoGn: Go ve Gn noktalarından geçen doğru ile S ve N noktalarından geçen doğru arasında oluşan açıdır.

11-FMA: FH düzlemi ile Mandibular Düzlem (Go ve Me noktalarından geçen doğrudur) arasındaki açıdır.

12- Ön Yüz Yüksekliği: N ve Me noktaları arasındaki mesafedir.

13- Arka yüz yüksekliği: S ve Go noktaları arasındaki mesafedir.

14-Arka-Ön Yüz Yüksekliği Oranı: S ve Go noktaları arasındaki mesafe ile N ve Me noktaları arasındaki mesafenin oranıdır.

15-Alt Ön Yüz Yüksekliği: ANS ve Me noktaları arasındaki mesafedir.

16-Co-A: Co noktası ve A noktası arasındaki mesafedir.

17-Co-Gn: Co noktası ve Gn noktası arasındaki mesafedir.

18-Ön Kafa Kaidesi Uzunluğu (S-N): S ve N noktaları arasındaki doğrusal mesafedir.

19-Corpus Uzunluđu (Go-Me): Go ve Me noktaları arasındaki mesafedir.

20-U1/SN: Üst ön keser dişin uzun eksenini ile S ve N noktalarından geçen doğruyunun arasında oluşan açıdır.

22-U1/PP: Üst ön keser dişin uzun eksenini ile ANS ve PNS noktalarından geçen doğruyunun arasında oluşan açıdır.

23-U1-NA (mm): Üst ön keser dişin apikali ile N ve A noktalarından geçen doğru arasındaki doğrusal mesafedir.

24-U1/NA: Üst ön keser dişin uzun eksenini ile N ve A noktalarından geçen doğruyunun arasında oluşan açıdır

25-U1/OP: Üst ön keser dişin uzun eksenini ile oklüzal düzlem arasında oluşan açıdır.

26-L1-Apog: Alt ön keser dişin apikali ile A ve Pog noktalarından geçen doğru arasındaki doğrusal mesafedir.

27-L1-NB (mm): Alt ön keser diş apikali ile N ve B noktalarından geçen doğru arasındaki doğrusal mesafedir.

28-L1/NB: Alt ön keser dişin uzun eksenini ile N ve B noktaları arasından geçen doğru arasında oluşan açıdır.


29-L1/OP: Alt ön keser dişin uzun eksenini ile oklüzal düzlem arasında oluşan açıdır.

30-İnterinsizal Açısı (U1/L1): Üst ve alt ön keser dişlerin uzun eksenleri arasından oluşan açıdır.

31-Nasolabial Açısı: Üst dudağın ön yüzü ile burun kolumellası ile arasındaki açıdır.


32-Üst Dudak protrüzyonu: Üst dudağın en ön noktası (Ls) ile E doğrusu (Prn ve Pog noktasından geçen doğrudur) arasındaki mesafedir.

33-Alt Dudak Protrüzyonu: Alt dudağın en ön noktası (Li) ile E doğrusu arasındaki mesafedir.



Şekil 3.16: Çalışmada kullanılan doğru ve düzlemler


1. SN (ön kafa kaidesi), 2. FH (Frankfurt horizontal düzlemi), 3. Go-Me (mandibuler düzlem),
4. NA doğrusu, 5. S-Gn (Y eksen), 6. N-Pog, 7. NB doğrusu, 8. N-Me (ön yüz yüksekliği) ,
9. S-Go (arka yüz yüksekliği)



Şekil 3.17: Çalışmamızda değerlendirilen sagittal ölçümler


1. SNA, 2. SNB, 3. ANB, 4. N-A, 5. N-Pog, 6. Wits (mm)

A. A Doğrusu, B. Oklüzal Düzlem




Şekil 3.18: Çalışmamızda değerlendirilen vertikal ölçümler

7. Y aksı açısı, 8. GoMe/SN, 9. SN/PP, 10. GoGn/SN, 11.FMA, 12. Ön Yüz Yüksekliği,
13. Arka Yüz Yüksekliği




Şekil 3.19: Çalışmamızda değerlendirilen çene boyutu ölçümleri

1.Alt Ön Yüz Yüksekliği, 2.Co-A, 3.Co-Gn, 4.Ön Kafa Kaidesi Uzunluğu, 5.Corpus Uzunluğu




Şekil 3.20: Çalışmamızda değerlendirilen üst keser ölçümleri

1.U1/SN, 2. U1/PP, 3.U1-NA, 4. U1/NA, 5.U1/PP



Şekil 3.21: Çalışmamızda değerlendirilen alt keser ölçümleri

1. L1-Apog, 2. IMPA, 3. L1-NB, 4. L1/NB, 5. L1/OP, 6.U1/L1



Şekil 3.22: Çalışmamızda değerlendirilen yumuşak doku ölçümleri
1. Nasolabial Aç1, 2. Üst Dudak Protrüzyonu, 3. Alt Dudak Protrüzyonu

50 BT görüntüsü ve yine aynı görüntülerden elde edilen 2 boyutlu sefalometrik radyografi 5 farklı analiz programında incelenmiştir. Gruplar sırasıyla; Nemoceph 3D (SurgeryFAB), Nemoceph 2D, AudaxCeph, OrthoDx ve WebCeph programlarından oluşmaktadır.

Tüm ölçümler tamamlandıktan sonra Nemoceph 3D SurgeryFAB analiz programında ölçülen değerler 'kesin referans' kabul edilmiş ve diğer gruplar ile tek tek karşılaştırılmıştır. Karşılaştırmalar yapıldıktan sonra Nemoceph 2D, AudaxCeph, OrthoDx ve WebCeph programlarının ölçüm değerlerinin Nemoceph 3D (SurgeryFAB) programından elde edilen ölçüm değerlerinden farkları karşılaştırılarak 4 yöntem birbiri arasında değerlendirilmiştir.

3.2.3 İstatistiksel yöntem

Tüm istatistiksel analizler bir istatistik yazılım programında (SPSS versiyon 26.0, IBM Corp.) gerçekleştirildi. Tanımlayıcı istatistikler için ortalama, standart sapma, minimum ve maksimum değerler hesaplandı. Kategorik veriler, frekans ve yüzde ile gösterildi. Verilerin normal dağılıma uygunluğu Shapiro-Wilk testi ve Kolmogorov-Smirnov testi incelenerek değerlendirildi. Verilerin normal dağılıma uyup uymamasına bağlı olarak, aynı sefalometrilere ait ölçümlerde farklı metotların karşılaştırılmasında tekrarlı ölçümler ANOVA ve Friedman testi kullanıldı. Post-hoc ikili grup karşılaştırmaları Bonferroni düzeltmesi ile yapıldı. Gözlemci içi güvenilirlik, sınıf içi korelasyon katsayısı (ICC) hesaplanarak değerlendirildi. Anlamlılık düzeyi 0,05 olarak belirlendi.

4 BULGULAR

4.1 Bireylerin Yaş ve Cinsiyet Dağılımı

Bu çalışmaya dahil edilen bireylerin yaş ve cinsiyet bilgilerini gösteren demografik veriler aşağıda sunulmuştur.

Tablo 4.1: Bireylerin yaş ve cinsiyet dağılımı

Cinsiyet	YAŞ			SINIF					
	n	Ortalama	Standart sapma	1		2		3	
				n	%	n	%	n	%
Erkek	23	25,30	5,83	5	21,7	5	21,7	13	56,5
Kadın	27	23,96	5,61	5	18,5	4	14,8	18	66,7

4.2 Sınıf İçi Korelasyon Katsayısı

Tablo 4.2: Sınıf içi korelasyon katsayısı

Intraclass Correlation Coefficient							
	Intraclass Correlation	95% Confidence Interval		F Test with True Value 0			
		Lower Bound	Upper Bound	Value	df1	df2	Sig
Single Measures	,970	,965	,974	65,887	659	659	,000
Average Measures	,985	,982	,987	65,887	659	659	,000

Gözlemci içi güvenilirlik, sınıf içi korelasyon katsayısı (ICC) hesaplanarak değerlendirildi. Sınıf içi korelasyon katsayısı[155]:

0.50'den az ise = Zayıf, 0.50 – 0.75 arası = Orta Düzeyde, 0.75 – 0.90 arası = İyi, 0.90 ve üzeri = Mükemmel

Çalışmamızda BT üzerinden NemoCeph 3D(Surgery FAB) analiz programı ile ilk işaretlemeden 4 ay sonra araştırmacının iç tutarlılığını tespit edebilme amacıyla, aynı araştırmacı tarafından rastgele 20 adet 3 boyutlu görüntü Nemoceph 3D(SurgeryFAB) programına bir kez daha yüklenmiş ve anatomik noktalar tekrar işaretlenmiştir. Aynı gözlemcinin aynı yöntemle farklı

zamandaki iki ölçümü arasındaki ICC 0,98'di. Gözlemci içi güvenilirliğin yüksek olarak değerlendirilmiştir.

4.3 NemoCeph 3D(Surgery FAB) Programında Yapılan Ölçümlerin NemoCeph (2D) Programı ve Yapay Zeka Programlarında Yapılan Ölçümlerinin Karşılaştırılması

Çalışmamıza dahil edilen 50 adet BT görüntüsü NemoCeph 3D(Surgery FAB) analiz programında, BT görüntülerinden üst üste bindirilmesiyle oluşturulan 2 boyutlu sefalometrik görüntüler NemoCeph (2D) programında, ve yapay zeka programları AudaxCeph, OrthoDx ve WebCeph ile SNA, SNB, ANB, N-A, N-Pog, Wits (mm), Y aksı açısı, GoMe/SN, SN/PP, GoGn/SN, FMA, ön yüz yüksekliği, arka yüz yüksekliği, arka-ön yüz yüksekliği oranı ,alt ön yüz yüksekliği, Co-A, Co-Gn, ön kafa kaidesi uzunluğu, corpus uzunluğu, U1/SN, U1/PP, U1-NA, U1/NA, U1/PP, L1-Apog, IMPA, L1-NB, L1/NB, L1/OP, U1/L1, nasolabial açı, üst dudak protrüzyonu, alt dudak protrüzyonu değerleri ölçüldü. NemoCeph 3D(Surgery FAB) programında yapılan ölçümler NemoCeph (2D) programı ve yapay zeka programları AudaxCeph, OrthoDx ve WebCeph ölçümleri ile ayrı ayrı karşılaştırılmıştır. NemoCeph 3D(Surgery FAB) programı ile yapılan ölçümler 3D olarak, NemoCeph (2D) programı ile yapılan ölçümler 2D, AudoxCeph programı ile yapılan ölçümler AC, OrthoDx programı ile yapılan ölçümler OD ve WebCeph programı ile yapılan ölçümler WC kısaltmalarıyla belirtilmiştir.

Tablo 4.3: NemoCeph 3D(Surgery FAB) programı ile NemoCeph (2D) programında yapılan ölçümlerin karşılaştırılması

	3D				2D				Farklılıklar				p- değeri
	Ort.	SS	Min.	Mak.	Ort.	SS	Min.	Mak.	Ort.	SS	Min.	Mak.	
SNA	77,7	3,3	71	86	76,3	11,2	2	86	1,4	-7,9	69	0	1
SNB	78,6	5,7	65	89	78,9	5,6	64	89	-0,3	0,1	1	0	1
ANB	-0,9	4,9	-11	12	-0,9	5	-11	11	0	-0,1	0	1	1
N-A	-2,5	4,5	-10,2	8,8	-3,1	6,1	-12	8,2	0,6	-1,6	1,8	0,6	1
N-Pog	-0,6	11,6	-45,2	17,7	0	11,7	-43,3	24,2	-0,6	-0,1	-1,9	-6,5	1
Wits	-7,1	7	-20,3	10,4	-6,4	7,6	-19,8	17,3	-0,7	-0,6	-0,5	-6,9	1
Y Aksı Açısı	61,1	6	51	79	61,2	6,2	50	79	-0,1	-0,2	1	0	1
GoMe/SN	41,1	8	21	66	41,6	8	24	66	-0,5	0	-3	0	1
SN/PP	9,1	3,6	2	17	10	3,5	3	17	-0,9	0,1	-1	0	0,009*
SN/GoGn	39,1	7,8	19	63	39,4	7,7	21	65	-0,3	0,1	-2	-2	1
FMA	31,7	7,7	12	57	32,2	7,4	16	59	-0,5	0,3	-4	-2	0,291
Ön Yüz Yüksekliği	123,9	10,5	99	144,8	123,7	9,8	101,6	142,2	0,2	0,7	-2,6	2,6	1
Arka Yüz Yüksekliği	79,3	7,6	66,1	95,9	78,3	11,8	63,6	96,2	1	-4,2	2,5	-0,3	0,666
Arka-Ön Yüz Yüksekliği Oranı	64,2	5,9	51,8	84,2	64,8	6,2	52,2	84,8	-0,6	-0,3	-0,4	-0,6	0,766
Alt Ön Yüz Yüksekliği	73	9,1	51,2	96,1	73,4	9	52,3	97,6	-0,4	0,1	-1,1	-1,5	0,097
Co-A	79,4	6,1	63,6	91,3	79,4	6,1	64	91,6	0	0	-0,4	-0,3	1
Co-Gn	118,2	9,7	101,6	140,8	118,2	9,6	102,6	138,6	0	0,1	-1	2,2	1
Ön Kafa Kaidesi Uzunluğu	66,3	3,9	57,1	76	66,7	3,9	58,2	75,5	-0,4	0	-1,1	0,5	0,621
Go-Me	70,3	6,1	58,4	81,6	71,4	7,4	58,1	97,6	-1,1	-1,3	0,3	-16	0,248
UI/SN	102,1	8,2	83	117	102,7	7,9	85	118	-0,6	0,3	-2	-1	0,029*
UI/PP	111,2	8	91	123	111,5	7,8	92	123	-0,3	0,2	-1	0	1
UI-NA (mm.)	5,2	3	-1,3	12,4	5,1	2,9	-1,9	10,6	0,1	0,1	0,6	1,8	1
UI/NA (Açı)	24,4	8,5	4	39	25,1	8	5	39	-0,7	0,5	-1	0	0,002*
UI/OP	58	6,1	47	72	57,7	7,6	38	73	0,3	-1,5	9	-1	0,282
LI-APog(mm)	5,1	3,9	-5,4	13,8	5	3,6	-5,2	12,7	0,1	0,3	-0,2	1,1	0,992
IMPA	88,4	8,4	62	101	89,1	8,1	61	102	-0,7	0,3	1	-1	0,341
LI-NB (mm.)	5,5	3,2	-2,5	13,6	5,2	3,2	-3,1	12,8	0,3	0	0,6	0,8	0,272
LI/NB (Açı)	26,6	8,4	2	42	27,5	7,9	4	43	-0,9	0,5	-2	-1	<0,001*
LI/OP	70,6	8,2	54	91	70,2	8,3	58	91	0,4	-0,1	-4	0	1
İnterinsizal Açı	129,9	10,4	103	151	131,1	41,1	109	154	-1,2	-30,7	-6	-3	1
Nasolabial Açı	98,1	13,5	61	128	98,3	12,9	63	128	-0,2	0,6	-2	0	1
Üst Dudak Protrüzyonu	-4,1	3,6	-9,3	6,7	-3,9	3,5	-8,8	6,9	-0,2	0,1	-0,5	-0,2	1
Alt Dudak Protrüzyonu	0,2	3,7	-7,8	8,1	0,1	3,7	-7,3	7,6	0,1	0	-0,5	0,5	1

*p<0,05, **p<0,001, Ort.=ortalama, SS=standart sapma, Min.=minimum, Mak.=Maksimum

3D ile 2D Nemoceph programlarında yapılan ölçümler karşılaştırıldığında SN-PP, U1/SN, U1/NA ve L1-NB ölçümlerinde istatistiksel olarak anlamlı farklar bulunmuştur. Bu ölçümler dışındaki ölçümlerde anlamlı bir fark bulunamamıştır.



Tablo 4.4: NemoCeph 3D(Surgery FAB) programı ile AudoxCeph programında yapılan ölçümlerin karşılaştırılması

	3D				AC				Farklılıklar				p-değeri
	Ort.	SS	Min.	Mak.	Ort.	SS	Min.	Mak.	Ort.	SS	Min.	Mak.	
SNA	77,7	3,3	71	86	77,7	2,8	72	84	0	0,5	-1	2	1
SNB	78,6	5,7	65	89	78,4	5,3	64,2	87,1	0,2	0,4	0,8	1,9	1
ANB	-0,9	4,9	-11	12	-0,6	4,7	-10,8	11,9	-0,3	0,2	-0,2	0,1	1
N-A	-2,5	4,5	-10,2	8,8	-5,5	2,9	-11,2	1	3	1,6	1	7,8	1
N-Pog	-0,6	11,6	-45,2	17,7	-7,4	11,6	-38,7	10	6,8	0	-6,5	7,7	1
Wits	-7,1	7	-20,3	10,4	-6,5	7,2	-20,8	12,1	-0,6	-0,2	0,5	-1,7	1
Y Aksı Açısı	61,1	6	51	79	64	5,7	53,5	79,6	-2,9	0,3	-2,5	-0,6	1
GoMe/SN	41,1	8	21	66	42,5	7,9	24	68	-1,4	0,1	-3	-2	1
SN/PP	9,1	3,6	2	17	10,4	3,3	4,1	18,3	-1,3	0,3	-2,1	-1,3	0,009*
SN/GoGn	39,1	7,8	19	63	40,7	8,2	18,6	66,1	-1,6	-0,4	0,4	-3,1	1
FMA	31,7	7,7	12	57	32,9	8,2	10,4	58,8	-1,2	-0,5	1,6	-1,8	0,291
Ön Yüz Yüksekliği	123,9	10,5	99	144,8	123,7	9,8	101,6	142,2	0,2	0,7	-2,6	2,6	1
Arka Yüz Yüksekliği	79,3	7,6	66,1	95,9	77,3	11,8	15,6	96,2	2	-4,2	50,5	-0,3	0,666
Arka-Ön Yüz Yüksekliği Oranı	64,2	5,9	51,8	84,2	60,4	5,5	48	76,5	3,8	0,4	3,8	7,7	0,766
Alt Ön Yüz Yüksekliği	73	9,1	51,2	96,1	73,8	9	52,3	97,6	-0,8	0,1	-1,1	-1,5	0,097
Co-A	79,4	6,1	63,6	91,3	79,9	6,1	64	91,6	-0,5	0	-0,4	-0,3	1
Co-Gn	118,2	9,7	101,6	140,8	117,2	9,6	102,6	138,6	1	0,1	-1	2,2	1
Ön Kafa Kaidesi Uzunluğu	66,3	3,9	57,1	76	66,3	4,7	56,2	81,4	0	-0,8	0,9	-5,4	0,621
Go-Me	70,3	6,1	58,4	81,6	72,4	7,4	58,1	97,6	-2,1	-1,3	0,3	-16	0,248
UI/SN	102,1	8,2	83	117	101,5	7,3	82,3	115,3	0,6	0,9	0,7	1,7	0,029*
UI/PP	111,2	8	91	123	111,6	7,3	91,8	121,4	-0,4	0,7	-0,8	1,6	1
UI-NA (mm.)	5,2	3	-1,3	12,4	4,9	2,6	-1,9	9,8	0,3	0,4	0,6	2,6	1
UI/NA (Açı)	24,4	8,5	4	39	23,8	7,4	3,8	38,2	0,6	1,1	0,2	0,8	0,002*
UI/OP	58	6,1	47	72	56,7	7,6	28	73	1,3	-1,5	19	-1	0,282
LI-APog(mm)	5,1	3,9	-5,4	13,8	5,7	3,7	-6,1	15,2	-0,6	0,2	0,7	-1,4	0,992
IMPA	88,4	8,4	62	101	85,4	8,1	68,1	104	3	0,3	-6,1	-3	0,341
LI-NB (mm.)	5,5	3,2	-2,5	13,6	6,3	3,5	-2,2	17,9	-0,8	-0,3	-0,3	-4,3	0,272
LI/NB (Açı)	26,6	8,4	2	42	26,8	8	4	40,2	-0,2	0,4	-2	1,8	<0,001*
LI/OP	70,6	8,2	54	91	72,2	8,3	58	91	-1,6	-0,1	-4	0	1
İnterinsizal Açı	129,9	10,4	103	151	130,1	10,6	104,7	150,8	-0,2	-0,2	-1,7	0,2	1
Nasolabial Açı	98,1	13,5	61	128	97,4	19,7	3,4	125,4	0,7	-6,2	57,6	2,6	1
Üst Dudak Protrüzyonu	-4,1	3,6	-9,3	6,7	7,5	8,1	-7,2	38,8	-11,6	-4,5	-2,1	-32,1	1
Alt Dudak Protrüzyonu	0,2	3,7	-7,8	8,1	14,2	9,1	-6,5	35,9	-14	-5,4	-1,3	-27,8	1

3D ile AudoxCeph programlarında yapılan ölçümler karşılaştırıldığında N-A, N-Pog, Y aksı açısı, GoMe/SN, GoGn/SN, arka-ön yüz yüksekliği oranı, IMPA, üst dudak protrüzyonu ve alt dudak protrüzyonu ölçümlerinde istatistiksel olarak anlamlı farklar bulunmuştur. Bu ölçümler dışındaki ölçümlerde anlamlı bir fark bulunamamıştır.



Tablo 4.5: NemoCeph 3D(Surgery FAB) programı ile OrthoDx programında yapılan ölçümlerin karşılaştırılması

	3D				OD				Farklılıklar				p-değeri
	Ort.	SS	Min.	Mak.	Ort.	SS	Min.	Mak.	Ort.	SS	Min.	Mak.	
SNA	77,7	3,3	71	86	76,9	3	70	83	0,8	0,3	1	3	1
SNB	78,6	5,7	65	89	77,8	5,1	63	86	0,8	0,6	2	3	1
ANB	-0,9	4,9	-11	12	-0,9	5	-12	12	0	-0,1	1	0	1
N-A	-2,5	4,5	-10,2	8,8	6,5	3,3	-0,1	13,6	-9	1,2	-10,1	-4,8	1
N-Pog	-0,6	11,6	-45,2	17,7	8,5	10,9	-9,5	37,5	-9,1	0,7	-35,7	-19,8	1
Wits	-7,1	7	-20,3	10,4	-8,2	6	-20,6	4,2	1,1	1	0,3	6,2	1
Y Aksı Açısı	61,1	6	51	79	59,3	6,1	43	79	1,8	-0,1	8	0	1
GoMe/SN	41,1	8	21	66	43	7,7	25	68	-1,9	0,3	-4	-2	1
SN/PP	9,1	3,6	2	17	11,2	4,1	4	23	-2,1	-0,5	-2	-6	0,009*
SN/GoGn	39,1	7,8	19	63	38	8	20	64	1,1	-0,2	-1	-1	1
FMA	31,7	7,7	12	57	29,1	7,2	11	48	2,6	0,5	1	9	0,291
Ön Yüz Yüksekliği	123,9	10,5	99	144,8	122,7	10,5	96	144	1,2	0	3	0,8	1
Arka Yüz Yüksekliği	79,3	7,6	66,1	95,9	62,5	6,4	51	78	16,8	1,2	15,1	17,9	0,666
Arka-Ön Yüz Yüksekliği Oranı	64,2	5,9	51,8	84,2	61,3	5,5	48	73	2,9	0,4	3,8	11,2	0,766
Alt Ön Yüz Yüksekliği	73	9,1	51,2	96,1	69,3	8,3	51	88	3,7	0,8	0,2	8,1	0,097
Co-A	79,4	6,1	63,6	91,3	82,5	6,4	67	96	-3,1	-0,3	-3,4	-4,7	1
Co-Gn	118,2	9,7	101,6	140,8	122,3	9,1	107	141	-4,1	0,6	-5,4	-0,2	1
Ön Kafa Kaidesi Uzunluğu	66,3	3,9	57,1	76	67,4	4,5	58	77	-1,1	-0,6	-0,9	-1	0,621
Go-Me	70,3	6,1	58,4	81,6	77,9	6,2	64	96	-7,6	-0,1	-5,6	-14,4	0,248
UI/SN	102,1	8,2	83	117	102,6	6,7	86	119	-0,5	1,5	-3	-2	0,029*
UI/PP	111,2	8	91	123	113,4	7,3	97	129	-2,2	0,7	-6	-6	1
UI-NA (mm.)	5,2	3	-1,3	12,4	6,3	3,8	1,1	20	-1,1	-0,8	-2,4	-7,6	1
UI/NA (Açı)	24,4	8,5	4	39	25,4	7,7	8	44	-1	0,8	-4	-5	0,002*
UI/OP	58	6,1	47	72	66,7	7	52	82	-8,7	-0,9	-5	-10	0,282
LI-APog(mm)	5,1	3,9	-5,4	13,8	5,3	3,4	-4,1	12,7	-0,2	0,5	-1,3	1,1	0,992
IMPA	88,4	8,4	62	101	90,6	9,4	71	115	-2,2	-1	-9	-14	0,341
LI-NB (mm.)	5,5	3,2	-2,5	13,6	5,7	2,8	0,5	12	-0,2	0,4	-3	1,6	0,272
LI/NB (Açı)	26,6	8,4	2	42	29,1	8,6	6	46	-2,5	-0,2	-4	-4	<0,001*
LI/OP	70,6	8,2	54	91	72,3	8,9	53	107	-1,7	-0,7	1	-16	1
İnterinsizal Açı	129,9	10,4	103	151	126,2	11,7	102	151	3,7	-1,3	1	0	1
Nasolabial Açı	98,1	13,5	61	128	98,4	12,5	69	131	-0,3	1	-8	-3	1
Üst Dudak Protrüzyonu	-4,1	3,6	-9,3	6,7	-3,6	3,3	-8,8	6,2	-0,5	0,3	-0,5	0,5	1
Alt Dudak Protrüzyonu	0,2	3,7	-7,8	8,1	1,46	3,9	-6,8	8	-1,26	-0,2	-1	0,1	1

3D ile OrthoDx programlarında yapılan ölçümler karşılaştırıldığında SNB, N-A, GoMe/SN, SN/PP, FMA, arka yüz yüksekliği, arka-ön yüz yüksekliği Oranı, alt ön yüz yüksekliği, ön kafa kaidesi uzunluğu Co-A, Co-Gn, Go-Me, U1/OP, IMPA ve L1/NB ölçümlerinde istatistiksel olarak anlamlı farklar bulunmuştur. Bu ölçümler dışındaki ölçümlerde anlamlı bir fark bulunamamıştır.



Tablo 4.6: NemoCeph 3D(Surgery FAB) programı ile WebCeph programında yapılan ölçümlerin karşılaştırılması

	3D				WC				Farklılıklar				p-değeri
	Ort.	SS	Min.	Mak.	Ort.	SS	Min.	Mak.	Ort.	SS	Min.	Mak.	
SNA	77,7	3,3	71	86	75,9	2,9	69	82	1,8	0,4	2	4	1
SNB	78,6	5,7	65	89	76,5	5,3	62	84	2,1	0,4	3	5	1
ANB	-0,9	4,9	-11	12	-0,6	4,6	-10	13	-0,3	0,3	-1	-1	1
N-A	-2,5	4,5	-10,2	8,8	-2	5,5	-13	10,5	-0,5	-1	2,8	-1,7	1
N-Pog	-0,6	11,6	-45,2	17,7	-0,6	11,2	-45	15,4	0	0,4	-0,2	2,3	1
Wits	-7,1	7	-20,3	10,4	-7,3	6,8	-23,9	11	0,2	0,2	3,6	-0,6	1
Y Aksı Açısı	61,1	6	51	79	71,2	5,9	60	87	-10,1	0,1	-9	-8	1
GoMe/SN	41,1	8	21	66	40,4	8,7	16	68	0,7	-0,7	5	-2	1
SN/PP	9,1	3,6	2	17	12,1	2	8	17	-3	1,6	-6	0	0,009*
SN/GoGn	39,1	7,8	19	63	28,2	8,6	7	56	10,9	-0,8	12	7	1
FMA	31,7	7,7	12	57	29,4	7,9	7	56	2,3	-0,2	5	1	0,291
Ön Yüz Yüksekliği	123,9	10,5	99	144,8	125,5	12,7	87,1	146,8	-1,6	-2,2	11,9	-2	1
Arka Yüz Yüksekliği	79,3	7,6	66,1	95,9	77,1	8,1	58,8	96,8	2,2	-0,5	7,3	-0,9	0,666
Arka-Ön Yüz Yüksekliği Oranı	64,2	5,9	51,8	84,2	64,2	5,7	52	79	0	0,2	-0,2	5,2	0,766
Alt Ön Yüz Yüksekliği	73	9,1	51,2	96,1	71	8,9	48,1	92,7	2	0,2	3,1	3,4	0,097
Co-A	79,4	6,1	63,6	91,3	79,9	6,8	61,2	93,3	-0,5	-0,7	2,4	-2	1
Co-Gn	118,2	9,7	101,6	140,8	117,2	12,2	83,2	140,1	1	-2,5	18,4	0,7	1
Ön Kafa Kaidesi Uzunluğu	66,3	3,9	57,1	76	68	6,4	52,8	83,9	-1,7	-2,5	4,3	-7,9	0,621
Go-Me	70,3	6,1	58,4	81,6	72,5	7,6	53,3	89,5	-2,2	-1,5	5,1	-7,9	0,248
UI/SN	102,1	8,2	83	117	101,5	7,1	82	116	0,6	1,1	1	1	0,029*
UI/PP	111,2	8	91	123	113,6	7,3	94	129	-2,4	0,7	-3	-6	1
UI-NA (mm.)	5,2	3	-1,3	12,4	4,8	2,1	0,5	9	0,4	0,9	-1,8	3,4	1
UI/NA (Açı)	24,4	8,5	4	39	25,6	7,7	6	43	-1,2	0,8	-2	-4	0,002*
UI/OP	58	6,1	47	72	58,7	5,2	47	71	-0,7	0,9	0	1	0,282
LI-APog(mm)	5,1	3,9	-5,4	13,8	4,9	3,3	-3,8	13,2	0,2	0,6	-1,6	0,6	0,992
IMPA	88,4	8,4	62	101	91,1	8,3	68	109	-2,7	0,1	-6	-8	0,341
LI-NB (mm.)	5,5	3,2	-2,5	13,6	5,6	2,9	0,4	12,2	-0,1	0,3	-2,9	1,4	0,272
LI/NB (Açı)	26,6	8,4	2	42	27,9	7,2	3	42	-1,3	1,2	-1	0	<0,001*
LI/OP	70,6	8,2	54	91	72,5	9	52	94	-1,9	-0,8	2	-3	1
İnterinsizal Açı	129,9	10,4	103	151	127,1	9,8	98	153	2,8	0,6	5	-2	1
Nasolabial Açı	98,1	13,5	61	128	91,7	12,6	60,3	119	6,4	0,9	0,7	9	1
Üst Dudak Protrüzyonu	-4,1	3,6	-9,3	6,7	-7	4,1	-16	5	2,9	-0,5	6,7	1,7	1
Alt Dudak Protrüzyonu	0,2	3,7	-7,8	8,1	-2,9	3,5	-11	6	3,1	0,2	3,2	2,1	1

3D ile WebCeph programlarında yapılan ölçümler karşılaştırıldığında SNA, SNB, Y aksı açısı, SN/PP, SN/GoGn, FMA, ön kafa kaidesi uzunluğu, Go-Me, IMPA, nasolabial açısı, üst dudak protrüzyonu ve alt dudak protrüzyonu ölçümlerinde istatistiksel olarak anlamlı farklar bulunmuştur. Bu ölçümler dışındaki ölçümlerde anlamlı bir fark bulunamamıştır.

4.4 Diğer Yöntemlerin NemoCeph 3D Programında Yapılan Ölçümlerden Farklarının Karşılaştırılması

Yapılan ölçümler Nemoceph 3D(Surgery FAB) ile tek karşılaştırıldıktan sonra, NemoCeph 3D(Surgery FAB) ile ölçülen değerler arasındaki farklar kaydedilmiştir. Kaydedilen farklar ile elde edilen 4 grupta NemoCeph 2D, Audox, OrthoDx ve Webceph kendi aralarında karşılaştırılmıştır. Gruplar:

NemoCeph 3D(Surgery FAB) ile NemoCeph arasındaki farkların ölçülmesiyle (2D olarak adlandırıldı),

NemoCeph 3D(Surgery FAB) ile Audox arasındaki farkların ölçülmesiyle (Audox olarak adlandırıldı),

NemoCeph 3D(Surgery FAB) ile OrthoDx arasındaki farkların ölçülmesiyle (OrthoDx olarak adlandırıldı) ve

NemoCeph 3D(Surgery FAB) ile Webceph arasındaki farkların ölçülmesiyle (WebCeph olarak adlandırıldı) oluşturuldu.


Tablo 4.7: NemoCeph 2D, Audox, OrthoDx ve Webceph yöntemlerinin karşılaştırılması

	NemoCeph					Audox					OrthoDx					WebCeph					p
	Ort.	SS	Medyan	Q1 (1.çeyreklik)	Q3 (3.çeyreklik)	Ort.	SS	Medyan	Q1 (1.çeyreklik)	Q3 (3.çeyreklik)	Ort.	SS	Medyan	Q1 (1.çeyreklik)	Q3 (3.çeyreklik)	Ort.	SS	Medyan	Q1 (1.çeyreklik)	Q3 (3.çeyreklik)	
SNA	0,58	0,57	1,00	0,00	1,00	1,34	1,04	1,15	0,50	2,00	2,06	1,96	1,50	1,00	3,00	2,64	1,96	2,95	1,00	3,00	<0,001*
SNB	0,40	0,57	0,00	0,00	1,00	1,14	0,96	1,00	0,40	1,70	1,70	1,87	1,00	0,00	2,00	2,47	1,70	2,00	1,00	3,00	<0,001*
ANB	0,67	0,68	1,00	0,00	1,00	0,98	1,18	0,60	0,20	1,30	1,11	1,12	1,00	0,00	2,00	1,24	1,23	1,00	0,40	2,00	0,061
N-A	0,54	1,14	0,35	0,20	0,60	3,66	3,41	2,45	1,00	5,20	8,09	4,36	7,40	5,30	10,60	4,48	3,05	3,75	2,10	5,80	<0,001*
N-Pog	0,66	0,89	0,40	0,30	0,60	6,20	4,59	5,65	2,60	9,40	8,26	4,73	8,25	5,30	11,30	6,74	4,83	6,90	2,60	10,40	<0,001*
Wits	0,59	0,50	0,50	0,30	0,70	1,86	1,82	1,30	0,70	2,40	3,39	2,90	2,70	1,00	4,90	2,23	2,05	1,70	0,80	3,10	<0,001*
Y Aksı Açısı	1,24	0,96	1,00	1,00	2,00	3,19	2,56	2,90	1,00	4,70	2,28	2,07	2,00	1,00	3,00	9,94	3,13	9,25	8,00	12,00	<0,001*
GoMe/SN	1,00	1,12	1,00	0,00	2,00	1,68	1,52	1,50	0,00	3,00	1,94	1,82	1,00	1,00	3,00	2,22	1,87	2,00	1,00	3,00	0,002*
SN/PP	1,20	0,81	1,00	1,00	2,00	1,82	1,91	1,15	0,50	2,60	2,60	2,39	2,00	1,00	4,00	3,43	2,46	3,00	2,00	5,60	<0,001*
SN/Go Gn	1,04	0,90	1,00	0,00	2,00	2,11	1,62	1,50	0,80	3,30	1,96	1,88	2,00	0,00	3,00	9,94	3,07	10,00	8,00	12,00	<0,001*
FMA	1,36	0,90	1,00	1,00	2,00	2,88	2,78	2,05	0,90	4,40	2,90	2,82	2,00	1,00	4,00	3,44	2,65	3,00	1,00	5,00	<0,001*
Ön Yüz Yüksekliği	1,20	0,82	1,00	0,50	1,70	1,26	0,98	1,00	0,50	1,70	3,86	3,38	2,80	1,30	5,30	5,36	4,81	3,00	1,40	9,80	<0,001*
Arka Yüz Yüksekliği	1,03	1,02	0,75	0,40	1,40	4,69	2,93	4,53	3,86	5,72	16,56	5,24	16,85	13,00	19,10	4,72	4,62	3,25	1,60	6,50	<0,001*
Arka-Ön Yüz Yüksekliği Oranı	1,07	1,34	0,70	0,40	1,00	3,98	2,33	3,90	1,90	5,60	3,58	2,55	3,10	1,40	5,00	2,00	2,59	1,00	0,70	2,00	<0,001*
Alt Ön Yüz Yüksekliği	0,82	0,62	0,60	0,40	1,20	1,82	1,72	1,67	0,92	2,86	3,99	3,83	3,10	1,10	5,70	4,17	3,84	3,30	1,30	5,50	<0,001*
Co-A	0,75	0,56	0,65	0,40	0,90	0,83	0,61	0,69	0,43	0,93	1,26	1,56	0,95	0,40	1,60	5,04	4,88	3,55	1,40	6,30	<0,001*
Co-Gn	1,17	1,63	0,75	0,50	1,50	3,17	2,23	2,55	2,06	3,72	2,36	1,95	2,25	1,30	3,00	5,16	4,22	3,95	2,00	7,40	<0,001*

Ön Kafa Kaidesi Uzunluğu	0,79	0,56	0,60	0,40	1,10	1,62	1,84	1,10	0,50	1,70	1,92	1,62	1,45	0,90	2,60	4,36	3,75	3,05	1,50	6,50	<0,001*
Go-Me	1,56	4,39	0,70	0,50	1,10	4,66	3,39	4,41	2,25	5,89	4,85	2,92	4,50	2,30	6,60	5,26	4,09	3,90	1,90	8,60	<0,001*
UI/SN	1,25	0,75	1,00	1,00	2,00	2,63	1,99	2,55	1,10	3,50	4,70	3,07	4,00	3,00	6,00	4,27	3,00	4,00	2,00	6,00	<0,001*
UI/PP	0,90	1,07	1,00	0,00	2,00	2,53	1,90	1,95	1,10	4,10	5,74	5,22	4,00	1,00	8,00	4,45	3,59	3,50	2,00	6,00	<0,001*
UI-NA (mm.)	0,42	0,45	0,35	0,30	0,40	1,25	1,45	0,70	0,30	1,40	3,00	3,58	1,70	1,10	3,60	1,84	1,30	1,65	0,80	2,70	<0,001*
UI/NA (Angle)	1,06	0,77	1,00	1,00	1,00	2,78	2,60	1,85	1,20	3,80	5,70	4,32	5,00	2,00	9,00	3,72	3,17	2,50	1,00	6,00	<0,001*
UI/OP	1,04	0,97	1,00	0,00	2,00	2,10	3,16	2,27	1,36	3,64	10,78	5,73	9,50	7,00	17,00	4,85	2,88	4,50	3,00	7,00	<0,001*
LI-APog (mm)	0,39	0,21	0,40	0,20	0,50	0,95	1,89	0,40	0,20	0,90	1,46	2,18	0,80	0,30	1,30	1,41	1,77	1,10	0,30	1,50	<0,001*
IMPA	1,10	0,97	1,00	0,00	2,00	4,38	2,81	3,80	2,30	6,00	4,16	3,60	3,00	1,00	6,00	3,88	3,76	3,50	1,00	5,00	<0,001*
LI-NB (mm.)	0,47	0,81	0,30	0,30	0,40	0,82	1,19	0,50	0,30	0,90	1,23	1,29	0,90	0,40	1,70	1,18	1,16	0,80	0,50	1,50	<0,001*
LI/NB (Angle)	1,22	0,86	1,00	1,00	2,00	2,28	1,60	1,85	1,10	3,60	3,98	3,82	3,00	2,00	5,00	3,27	3,51	2,00	1,00	5,00	<0,001*
LI/OP	1,28	1,18	1,00	0,00	2,00	1,88	1,72	1,63	0,86	3,12	4,72	3,56	4,00	2,00	7,00	8,13	6,15	7,00	3,00	11,00	<0,001*
İnterinsizal Açık	1,78	1,66	1,00	1,00	3,00	3,61	5,31	2,30	1,40	3,80	7,54	6,91	6,00	4,00	9,00	4,92	3,82	3,50	2,00	7,00	<0,001*
Nasolabial Açık	1,36	1,14	1,00	0,00	2,00	5,06	3,21	4,85	1,80	7,40	2,54	2,02	2,00	1,00	3,00	8,15	5,80	7,00	5,00	10,00	<0,001*
Üst Dudak Protrüzyonu	0,33	0,18	0,30	0,20	0,50	8,42	4,12	8,40	5,20	11,60	0,91	0,49	0,90	0,50	1,20	3,10	1,84	2,85	1,80	4,00	<0,001*
Alt Dudak Protrüzyonu	0,38	0,20	0,30	0,30	0,50	14,08	7,15	13,40	10,00	17,90	1,92	1,71	1,40	0,96	2,98	3,47	1,69	3,35	2,30	4,20	<0,001*


*p<0,05 (Kruskal Wallis testi), Kruskal Wallis testi sonucuna göre, ANB değeri (p=0,061) dışındaki tüm ölçümlerde gruplar arasında istatistiksel olarak anlamlı farklılık bulundu (p<0,05).

SNA° ölçümlerindeki en az sapma NemoCeph 2D grubunda görülürken ($0,58 \pm 0,57$), sırasıyla Audox ($1,34 \pm 1,04$), OrthoDx ($2,06 \pm 1,96$) ve WebCeph ($2,64 \pm 1,96$) gruplarında artış gösterdi. NemoCeph grubu tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). Audox ile OrthoDx grupları arasında ($p = 1,000$) ve OrthoDx ile WebCeph grupları arasında ($p = 0,424$) anlamlı bir farklılık yoktu.




Şekil 4.1: Yöntemlerin SNA ölçümünde karşılaştırılması

SNB° ölçümlerindeki en az sapma NemoCeph grubunda görülürken ($0,40 \pm 0,57$), sırasıyla Audox ($1,14 \pm 0,96$), OrthoDx ($1,70 \pm 1,87$) ve WebCeph ($2,47 \pm 1,70$) gruplarında artış gösterdi. 2D grubu tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). Audox ile OrthoDx grupları arasında ($p = 1,000$) anlamlı bir farklılık yoktu.




Şekil 4.2: Yöntemlerin SNB ölçümünde karşılaştırılması

ANB° ölçümlerindeki en az sapma 2D grubunda görülürken ($0,67 \pm 0,68$), sırasıyla Audox ($0,98 \pm 1,18$), OrthoDx ($1,11 \pm 1,12$) ve WebCeph ($1,24 \pm 1,23$) gruplarında artış gösterdi. Gruplar arasında anlamlı bir farklılık yoktu ($p=0,061$).




Şekil 4.3: Yöntemlerin ANB ölçümünde karşılaştırılması

N-A ölçümlerindeki en az sapma 2D grubunda görülürken ($0,54 \pm 1,14$), sırasıyla Audox ($3,66 \pm 3,41$), WebCeph ($4,48 \pm 3,05$) ve OrthoDx ($8,09 \pm 4,36$) gruplarında artış gösterdi. 2D grubu tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). Audox ile WebCeph grupları arasında ($p = 0,999$) anlamlı bir farklılık yoktu.




Şekil 4.4: Yöntemlerin N-A ölçümünde karşılaştırılması

N-Pog ölçümlerindeki en az sapma 2D grubunda görülürken ($0,66 \pm 0,89$), sırasıyla Audox ($6,20 \pm 4,59$), WebCeph ($6,74 \pm 4,83$) ve OrthoDx ($8,26 \pm 4,73$) gruplarında artış gösterdi. 2D grubu tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). Audox ile OrthoDx grupları arasında ($p = 0,386$), OrthoDx ile WebCeph grupları arasında ($p = 1,000$) ve Audox ile WebCeph grupları arasında ($p = 1,000$) anlamlı bir farklılık yoktu.




Şekil 4.5: Yöntemlerin N-Pog ölçümünde karşılaştırılması

Wits ölçümlerindeki en az sapma 2D grubunda görülürken ($0,59 \pm 0,50$), sırasıyla Audox ($1,86 \pm 1,82$), WebCeph ($2,23 \pm 2,05$) ve OrthoDx ($3,39 \pm 2,90$) gruplarında artış gösterdi. 2D grubu tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$).




Şekil 4.6: Yöntemlerin Wits ölçümünde karşılaştırılması

Y aksı açısı ölçümlerindeki en az sapma 2D grubunda görülürken ($1,24 \pm 0,96$), sırasıyla OrthoDx ($2,28 \pm 2,07$), Audox ($3,19 \pm 2,56$) ve WebCeph ($9,94 \pm 3,13$) gruplarında artış gösterdi. 2D grubu, OrthoDx grubu ile benzer sonuç gösterirken ($p=0,309$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). WebCeph grubu, diğer gruplardan istatistiksel olarak anlamlı yüksek sapma gösterdi ($p<0,05$).




Şekil 4.7: Yöntemlerin Y aksı açısı ölçümünde karşılaştırılması

SN/GoMe ölçümlerindeki en az sapma 2D grubunda görülürken ($1,00 \pm 1,12$), sırasıyla Audox ($1,68 \pm 1,52$), OrthoDx ($1,94 \pm 1,82$) ve WebCeph ($2,22 \pm 1,87$) gruplarında artış gösterdi. 2D grubu, Audox grubu ile benzer sonuç gösterirken ($p=0,125$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$).




Şekil 4.8: Yöntemlerin SN/GoMe ölçümünde karşılaştırılması

SN/PP ölçümlerindeki en az sapma 2D grubunda görülürken ($1,20 \pm 0,81$), sırasıyla Audox ($1,82 \pm 1,91$), OrthoDx ($2,60 \pm 2,39$) ve WebCeph ($3,43 \pm 2,46$) gruplarında artış gösterdi. 2D grubu, Audox grubu ile benzer sonuç gösterirken ($p=1,000$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$).




Şekil 4.9: Yöntemlerin SN/PP ölçümünde karşılaştırılması

SN/GoGn ölçümlerindeki en az sapma 2D grubunda görülürken ($1,04 \pm 0,90$), sırasıyla OrthoDx ($1,96 \pm 1,88$), Audox ($2,11 \pm 1,62$) ve WebCeph ($9,94 \pm 3,07$) gruplarında artış gösterdi. 2D grubu, OrthoDx grubu ile benzer sonuç gösterirken ($p=0,351$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). WebCeph grubu, diğer tüm gruplardan anlamlı derecede yüksek sapma gösterdi ($p<0,05$).




Şekil 4.10: Yöntemlerin SN/GoGn ölçümünde karşılaştırılması

FMA ölçümlerindeki en az sapma 2D grubunda görülürken ($1,36 \pm 0,90$), sırasıyla Audox ($2,88 \pm 2,78$), OrthoDx ($2,90 \pm 2,82$) ve WebCeph ($3,44 \pm 2,65$) gruplarında artış gösterdi. 2D grubu tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). Audox ile OrthoDx grupları arasında ($p = 1,000$), OrthoDx ile WebCeph grupları arasında ($p = 0,805$) ve Audox ile WebCeph grupları arasında ($p = 0,946$) anlamlı bir farklılık yoktu.




Şekil 4.11: Yöntemlerin FMA ölçümünde karşılaştırılması

Ön yüz yüksekliği ölçümlerindeki en az sapma 2D grubunda görülürken ($1,20 \pm 0,82$), sırasıyla Audox ($1,26 \pm 0,98$), OrthoDx ($3,86 \pm 3,38$) ve WebCeph ($5,36 \pm 4,81$) gruplarında artış gösterdi. 2D grubu, Audox grubu ile benzer sonuç gösterirken ($p=1,000$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$).




Şekil 4.12: Yöntemlerin ön yüz yüksekliği ölçümünde karşılaştırılması

Arka yüz yüksekliği ölçümlerindeki en az sapma 2D grubunda ($1,03 \pm 1,02$) görülürken , sırasıyla Audox ($4,60 \pm 2,93$) WebCeph ($4,72 \pm 4,62$) ve OrthoDx ($16,56 \pm 5,24$) gruplarında artış gösterdi. 2D grubu, diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). OrthoDx grubu, diğer gruplardan anlamlı derecede daha yüksek sapma gösterdi ($p < 0,05$).




Şekil 4.13: Yöntemlerin arka yüz yüksekliği ölçümünde karşılaştırılması

Arka-ön yüz yüksekliği oranı ölçümlerindeki en az sapma 2D grubunda görülürken ($1,07 \pm 1,34$), sırasıyla WebCeph ($2,00 \pm 2,59$), OrthoDx ($3,58 \pm 2,55$) ve Audox ($3,98 \pm 2,33$) gruplarında artış gösterdi. 2D grubu, WebCeph grubu ile benzer sonuç gösterirken ($p=0,175$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). OrthoDx ile Audox grupları arasında ($p=1,000$) anlamlı bir farklılık yoktu.




Şekil 4.14: yöntemlerin arka-ön yüz yüksekliği oranı ölçümünde karşılaştırılması

Alt ön yüz yüksekliği ölçümlerindeki en az sapma 2D grubunda ($0,82 \pm 0,62$) görülürken, sırasıyla AudoxCeph ($1,82 \pm 1,72$) grubunda görülürken, sırasıyla OrthoDx ($3,99 \pm 3,83$) ve WebCeph ($4,17 \pm 3,84$) gruplarında artış gösterdi. 2D grubu, diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). OrthoDx ile WebCeph grupları arasında ($p = 1,000$) anlamlı bir farklılık yoktu.




Şekil 4.15: Yöntemlerin alt ön yüz yüksekliği oranı ölçümünde karşılaştırılması

Co-A ölçümlerindeki en az sapma 2D grubunda ($0,75 \pm 0,56$) grubunda görülürken, sırasıyla Audox ($0,83 \pm 0,61$) ,OrthoDx ($1,26 \pm 1,56$) ve WebCeph ($5,04 \pm 4,88$) gruplarında artış gösterdi. WebCeph grubu, diğer gruplardan anlamlı derecede daha yüksek sapma gösterdi ($p < 0,05$).




Şekil 4.16: Yöntemlerin Co-A ölçümünde karşılaştırılması

Co-Gn ölçümlerindeki en az sapma 2D grubunda ($1,17 \pm 1,63$) görülürken, sırasıyla OrthoDx ($2,36 \pm 1,95$), ve Audox ($3,17 \pm 2,23$) ve WebCeph ($5,16 \pm 4,22$) gruplarında artış gösterdi. 2D grubu diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$).




Şekil 4.17: Yöntemlerin Co-Gn ölçümünde karşılaştırılması

Ön kafa kaidesi uzunluğu ölçümlerindeki en az sapma 2D grubunda görülürken ($0,79 \pm 0,56$), sırasıyla Audox ($1,62 \pm 1,84$), OrthoDx ($1,92 \pm 1,62$) ve WebCeph ($4,36 \pm 3,75$) gruplarında artış gösterdi. 2D grubu, Audox grubu ile benzer sonuç gösterirken ($p=0,051$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). OrthoDx ile Audox grupları arasında ($p=0,685$) anlamlı bir farklılık yoktu.




Şekil 4.18: Yöntemlerin ön kafa kaidesi uzunluğu ölçümünde karşılaştırılması

Go-Me ölçümlerindeki en az sapma 2D grubunda ($1,56 \pm 4,39$) görülürken, sırasıyla Audox ($4,66 \pm 3,39$), OrthoDx ($4,85 \pm 2,92$) ve grubunda ve WebCeph ($5,26 \pm 4,09$) gruplarında artış gösterdi. 2D grubu diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$).




Şekil 4.19: Yöntemlerin Go-Me ölçümünde karşılaştırılması

UI/SN ölçümlerindeki en az sapma 2D grubunda görülürken ($1,25 \pm 0,75$), sırasıyla Audox ($2,63 \pm 1,99$), WebCeph ($4,37 \pm 3,00$) ve OrthoDx ($4,70 \pm 3,07$) gruplarında artış gösterdi. 2D grubu, tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). OrthoDx ile WebCeph grupları arasında ($p = 1,000$) anlamlı bir farklılık yoktu.




Şekil 4.20: Yöntemlerin UI/SN ölçümünde karşılaştırılması

UI/PP ölçümlerindeki en az sapma 2D grubunda görülürken ($0,90 \pm 1,07$), sırasıyla Audox ($2,53 \pm 1,90$), WebCeph ($4,45 \pm 3,59$) ve OrthoDx ($5,74 \pm 5,22$) gruplarında artış gösterdi. 2D grubu, tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). Audox ile OrthoDx grupları arasında ($p = 0,085$), OrthoDx ile WebCeph grupları arasında ($p = 1,000$) ve Audox ile WebCeph grupları arasında ($p = 0,130$) anlamlı bir farklılık yoktu.




Şekil 4.21: Yöntemlerin UI/PP ölçümünde karşılaştırılması

UI-NA ölçümlerindeki en az sapma 2D grubunda görülürken ($0,42 \pm 0,45$), sırasıyla Audox ($1,25 \pm 1,45$), WebCeph ($1,84 \pm 1,30$) ve OrthoDx ($3,00 \pm 3,58$) gruplarında artış gösterdi. 2D grubu, tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). OrthoDx ile WebCeph grupları arasında ($p = 1,000$) anlamlı bir farklılık yoktu.




Şekil 4.22: Yöntemlerin UI-NA ölçümünde karşılaştırılması

UI/NA ölçümlerindeki en az sapma 2D grubunda görülürken ($1,06 \pm 0,77$), sırasıyla Audox ($2,78 \pm 2,60$), WebCeph ($3,72 \pm 3,17$) ve OrthoDx ($5,70 \pm 4,32$) gruplarında artış gösterdi. 2D grubu, tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). OrthoDx ile WebCeph grupları arasında ($p = 0,158$) ve Audox ile WebCeph grupları arasında ($p = 1,000$) anlamlı bir farklılık yoktu.




Şekil 4.23: Yöntemlerin UI/NA ölçümünde karşılaştırılması

UI/OP ölçümlerindeki en az sapma 2D grubunda görülürken ($1,04 \pm 0,97$), sırasıyla Audox ($2,10 \pm 3,16$), WebCeph ($4,85 \pm 2,88$) ve OrthoDx ($10,78 \pm 5,73$) gruplarında artış gösterdi. 2D grubu, diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). OrthoDx grubu, diğer gruplardan anlamlı derecede daha yüksek sapma gösterdi ($p < 0,05$).




Şekil 4.24: Yöntemlerin UI/OP ölçümünde karşılaştırılması

LI-APog ölçümlerindeki en az sapma 2D grubunda görülürken ($0,39 \pm 0,21$), sırasıyla Audox ($0,95 \pm 1,89$), WebCeph ($1,41 \pm 1,77$) ve OrthoDx ($1,46 \pm 2,18$) gruplarında artış gösterdi. 2D grubu, Audox grubu ile benzer sonuç gösterirken ($p=0,933$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). OrthoDx ile WebCeph grupları arasında ($p=1,000$) ve Audox ile orthodx grupları arasında ($p=0,173$) anlamlı bir farklılık yoktu.




Şekil 4.25: Yöntemlerin LI-Apog ölçümünde karşılaştırılması

IMPA ölçümlerindeki en az sapma 2D grubunda görülürken ($1,10 \pm 0,97$), sırasıyla WebCeph ($3,88 \pm 3,76$), OrthoDx ($4,16 \pm 3,60$) ve Audox ($4,38 \pm 2,81$), gruplarında gösterdi. 2D grubu, tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). Audox ile OrthoDx grupları arasında ($p = 1,000$), OrthoDx ile WebCeph grupları arasında ($p = 1,000$) ve Audox ile WebCeph grupları arasında ($p = 0,570$) anlamlı bir farklılık yoktu.




Şekil 4.26: Yöntemlerin IMPA ölçümünde karşılaştırılması

LI-NB ölçümlerindeki en az sapma 2D grubunda görülürken ($0,47 \pm 0,81$), sırasıyla Audox ($0,82 \pm 1,19$), WebCeph ($1,18 \pm 1,16$) ve OrthoDx ($1,23 \pm 1,29$) gruplarında gösterdi. 2D grubu, Audox grubu ile benzer sonuç gösterirken ($p=0,158$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). Audox ile OrthoDx grupları arasında ($p=0,075$), OrthoDx ile WebCeph grupları arasında ($p=1,000$) ve Audox ile WebCeph grupları arasında ($p=0,143$) anlamlı bir farklılık yoktu.




Şekil 4.27: Yöntemlerin LI-NB ölçümünde karşılaştırılması

LI/NB ölçümlerindeki en az sapma 2D grubunda görülürken ($1,22 \pm 0,86$), sırasıyla Audox ($2,28 \pm 1,60$), WebCeph ($3,27 \pm 3,51$) ve OrthoDx ($3,98 \pm 3,82$) gruplarında gösterdi. 2D grubu, tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). Audox ile OrthoDx grupları arasında ($p = 0,208$), OrthoDx ile WebCeph grupları arasında ($p = 0,656$) ve Audox ile WebCeph grupları arasında ($p = 1,000$) anlamlı bir farklılık yoktu.




Şekil 4.28: Yöntemlerin LI/NB ölçümünde karşılaştırılması

LI/OP ölçümlerindeki en az sapma 2D grubunda ($1,28 \pm 1,18$) görülürken, sırasıyla Audox ($1,88 \pm 1,72$), OrthoDx ($4,72 \pm 3,56$) ve WebCeph ($8,13 \pm 6,15$) gruplarında artış gösterdi. 2D grubu, diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p < 0,05$). OrthoDx ile WebCeph grupları arasında ($p = 0,056$) anlamlı bir farklılık yoktu.




Şekil 4.29: Yöntemlerin LI/OP ölçümünde karşılaştırılması

İnterinsizal açı ölçümlerindeki en az sapma 2D grubunda ($1,78 \pm 1,66$) görülürken, sırasıyla Audox ($3,61 \pm 5,31$), OrthoDx ($7,54 \pm 6,91$) ve WebCeph ($4,92 \pm 3,82$) gruplarında artış gösterdi. 2D grubu, Audox grubu ile benzer sonuç gösterirken ($p=0,105$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). OrthoDx ile WebCeph grupları arasında ($p=0,481$) ve Audox ile WebCeph grupları arasında ($p=0,137$) anlamlı bir farklılık yoktu.




Şekil 4.30: Yöntemlerin interinsizal açı ölçümünde karşılaştırılması

Nasolabial açı ölçümlerindeki en az sapma 2D grubunda ($1,36 \pm 1,14$) görülürken, sırasıyla OrthoDx ($2,54 \pm 2,02$), Audox ($5,06 \pm 3,21$) ve WebCeph ($8,15 \pm 5,80$) gruplarında artış gösterdi. 2D grubu, OrthoDx grubu ile benzer sonuç gösterirken ($p=0,131$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). Audox ile WebCeph grupları arasında ($p=0,140$) anlamlı bir farklılık yoktu.




Şekil 4.31: Yöntemlerin nasolabial açı ölçümünde karşılaştırılması

Üst dudak protrüzyonu ölçümlerindeki en az sapma 2D grubunda ($0,33\pm0,18$) görülürken, sırasıyla OrthoDx ($0,91\pm0,49$), WebCeph ($3,10\pm1,84$) ve Audox ($8,42\pm4,12$) gruplarında artış gösterdi. 2D grubu, tüm gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). Audox grubu, diğer gruplardan anlamlı derecede daha yüksek sapma gösterdi ($p<0,05$).



Şekil 4.32: Yöntemlerin üst dudak protrüzyonu ölçümünde karşılaştırılması

Alt dudak protrüzyonu ölçümlerindeki en az sapma 2D grubunda ($0,38 \pm 0,20$) görülürken, sırasıyla OrthoDx ($1,92 \pm 1,71$), WebCeph ($3,47 \pm 1,69$) ve Audox ($14,08 \pm 7,15$) gruplarında artış gösterdi. 2D grubu, OrthoDx grubu ile benzer sonuç gösterirken ($p=0,059$), diğer gruplardan anlamlı derecede düşük sapma gösterdi ($p<0,05$). Audox grubu, diğer gruplardan anlamlı derecede daha yüksek sapma gösterdi ($p<0,05$).



Şekil 4.33: Yöntemlerin üst dudak protrüzyonu ölçümünde karşılaştırılması

5 TARTIŞMA

5.1 Amacın Tartışılması

Sefalometrik radyografiler, ilk kez Broadbent tarafından tanıtıldığından bu yana, ortodontik teşhis, tedavi planlaması, iskeletsel büyüme tahmini ve tedavi sonuçlarının değerlendirilmesi için kullanılmıştır[1]. Günümüzde sefalometrik radyografi analizleri, ortodontik teşhis için standart bir araç olarak kabul edilmektedir.

Teknolojinin gelişmesi ile konvansiyonel sefalometrik analiz günümüzde yerini dijital sefalometrik analize bırakmıştır. Literatürde dijital sefalometrik analiz ile konvansiyonel sefalometrik analiz arasında anlamlı bir fark olmadığını kanıtlayan yayınlar bulunmaktadır[58, 66, 67]. Günümüzde sefalometrik analiz, bilgisayar programları desteğiyle, konvansiyonel yöntemle göre daha hızlı ve daha az hata ile yapılabilmektedir[57].

Yapay zekanın ilk adımları bilgisayar çağının başlamasıyla atılmıştır. Günümüz teknolojisi büyük miktarda veri depolayarak önemli gelişmeler sağlamıştır. Nesne ve ses tanıma, problem çözme, hastalıkları teşhis etme, tedaviye ihtiyaç olup olmadığına karar verme, elde edilen prognostik görüntüleri yorumlayarak teşhis koyma gibi birçok alanda yapay zeka kullanılmaktadır. Sağlık hizmetleri, yapay zeka uygulamalarını hayata geçirmesi zor bir sektör olsa da, tıbbi görüntüleme bu alanda en çok umut vaat eden alanlardan biridir[156].

Tam otomatik sefalometrik analiz kavramı, ilk kez 1988 yılında ortodonti alanında tanıtılmıştır[138]. Teknolojik ilerlemeler, bu konudaki çalışmaları hızlandırmıştır. Yapay zeka teknolojisinin ortodontiye olan etkisiyle, tam otomatik sefalometrik analiz yapabilen yazılımlar ortodonti kliniklerinde kullanılmaya başlanmıştır.

Ortodonti kliniklerinde kullanılan yapay zeka tabanlı tam otomatik sefalometrik analizler derin öğrenme modellerini kullanmaktadır. Derin öğrenme, yapay sinir ağlarının kullanıldığı çoklu işleme katmanlarından oluşan makine öğreniminin bir bileşenidir. Girdi verilerini analiz etmek için derin bir sinir ağında farklı hesaplama katmanlarına sahip ağı kullanır. Derin öğrenmenin amacı, özellik algılamayı iyileştirmek için kalıpları otomatik olarak tanımlayan bir sinir ağı oluşturmaktır[86]. MÖ modellerinden farklı olarak, yapılan eğitim sonucunda, sadece ham veriyi işleyerek çıkarım yapabilme özelliğine sahiptir[110].

Derin öğrenme modelleri ile çalışan tam otomatik sefalometrik analizler ham verileri işleyerek anatomik noktaların yerlerini tespit etmektedirler. YZ eğitim verilerinde aynı verinin tekrarlanması durumuna veri tekrarı denir. Bu durum aşırı uyum (over fitting) ve ön yargıya (bias) sebep olur[92, 94]. Derin öğrenme tabanlı sefalometrik analiz programlarına yüklenen sefalometrik görüntülerin büyük bir kısmını cerrahi ihtiyacı olmayan normal değerlere yakın hastalar oluşturmaktadır. Amerika Birleşik Devletleri'nde, ortognatik cerrahi ihtiyacı olan maloklüzyon veya yüz deformitesine sahip bireylerin oranı yaklaşık %2'dir[148]. Bütün veri havuzu içerisinde küçük bir bölümü oluşturan ortognatik cerrahi hastalarında, norm değerlerine yakın hastaların verileri ile eğitilmiş olan derin öğrenme sistemleri veri tekrarı ve bias sebebiyle hata yapmaya daha meyilli olabilir[92, 94]. Bu sebeple norm değerlerden sapması fazla olan ortognatik cerrahi hastalarında tam otomatik sefalometrik analizlerin anatomik noktaları doğru işaretleyebilme yeteneğinin sınırlı olduğu düşünülmektedir.

Yapay zeka teknolojisiyle otomatik işaretleme ve analiz yapabilen programların, günümüzde yaygın olarak kullanılan bilgisayar destekli dijital sefalometrik analiz yazılımları kadar güvenilir olup olmadığı üzerinde çalışmalar mevcuttur. Yassir ve arkadaşları, AutoCAD (manuel olarak işaret noktalarının tanımlanması) ile WebCeph'i (hem otomatik hem de yarı otomatik sefalometrik izleme) karşılaştırarak WebCeph'in doğruluğu ve güvenilirliği değerlendirdikleri çalışmalarında YZ destekli işaretlemelelere dikkat etmeleri ve gerektiğinde manuel ayarlamalar yapmaları gerektiği sonucuna varmışlardır[157]. 2021 yılında Schwendicke ve arkadaşları, yaptıkları meta-analizde otomatik sefalometrik anatomik nokta tespitinin doğruluğunu değerlendirmişler ve çoğu ölçümün klinik olarak kabul edilebilir toleranslar içinde anatomik noktaları tanıyabildiğini bulmuşlardır. Ancak bu umut verici sonuçlara rağmen sefalometrik görüntülerin otomatik analizi için YZ kullanımını inceleyen çoğu çalışmada yüksek ön yargı riski olduğunu da belirtmişlerdir[11]. Literatürde, yapay zeka algoritmalarını içeren yazılımları bilgisayar destekli dijital sefalometrik analiz sistemleriyle karşılaştıran çalışmalar mevcuttur[139, 158]. Ancak ortognatik cerrahi hastaları üzerinde değerlendirme yapan bir çalışma mevcut değildir. İskeletsel olarak normalden sapma seviyeleri fazla olan cerrahi hastalarında yapay zeka tabanlı tam otomatik sefalometrik analizlerin tutarlılık seviyesini ölçen bir çalışma bulunmamaktadır.

Broadbent tarafından geliştirilen ilk sefalostat ile hastanın kafası bir kafa tutucu tarafından tutularak kafasının yan ve ön röntgenlerin alınması mümkün olmuştur [1].

Broadbent analizi stereoskopik olması nedeniyle yüz ilişkilerinin üç boyutlu teşhisin yapılmasını sağlamıştır. BT görüntülemenin yaygınlaşmasıyla, 3 boyutlu analiz ve tanı geliştirme çabaları günümüzde daha da ilgi çekici hale gelmiştir.

Periago ve arkadaşları 3B ölçümlerini insan kafatası üzerindeki doğrudan ölçümlerle karşılaştırmış ve bu yeniden yapılandırılmış görüntülemenin kafatasının anatomik noktaları arasındaki gerçek doğrusal mesafeleri yansıttığını rapor etmişlerdir[159]. Bu çalışma, BT'nin sefalometrik ölçümler için altın standart olarak kabul edilmesi gerektiği fikrini desteklemektedir. Diğer araştırmacılar çeşitli pozlama protokollerinde 3 boyutlu yer işareti tanımlamanın doğruluğunu ve kesinliğini kanıtlamışlardır [160, 161]. 3 boyutlu sefalometrik analizler ile 2 boyutlu sefalometrik analizleri karşılaştıran çeşitli çalışmalar mevcuttur[162, 163].

Çalışmamızda çift çene ortognatik cerrahi gerektiren hastalarda cerrahi öncesinde BT'den elde edilen sefalometrik görüntülerden elde edilen 2 boyutlu görüntülerde yapay zekâ teknolojisiyle tabanlı tam otomatik sefalometrik analizleri bilgisayar destekli dijital sefalometrik analizler ve BT rekonstrüksiyonlarının sefalometrik ölçümleri ile karşılaştırılmıştır.

Santaro ve arkadaşları, bilgisayar destekli dijital ve konvansiyonel sefalometrik ölçüm tekniklerini karşılaştırdıkları çalışmalarında, sefalometrik ölçüm yöntemlerini değerlendiren bir çalışmanın, filmlerin kalitesi veya anatomi varyasyonları gibi birçok farklı faktöre bağlı olarak değişebilecek olan anatomik işaret noktalarına değil, ölçümlere ve ölçüm sonuçlarına odaklanması gerektiğini belirtmişlerdir[48]. Santaro, sefalometrik filmde başlayarak hastayı teşhis etmemizi sağlayan son ürün olduğunu ve bu sonucun değerlendirilmesinin önemli olduğunu ifade etmektedir. Kılınç ve arkadaşlarının yaptıkları çalışmada da anatomik noktaların pozisyonları değil ölçümler değerlendirilmiştir. Bizim çalışmamızda da bu çalışmalara uyumlu olarak sefalometrik ölçümler değerlendirilmiştir[164].

Bu çalışmanın amacı çift çene ortognatik cerrahi gerektiren hastalarda cerrahi öncesinde BT'den elde edilen 2 boyutlu sefalometrik görüntüler üzerinde yapay zeka teknolojisiyle yapılan otomatik sefalometrik analizleri bilgisayar destekli dijital sefalometrik analizler ve BT rekonstrüksiyonlarının sefalometrik ölçümleri ile karşılaştırmak ve yapay zeka tabanlı sefaometrik analizlerin yeterliliklerini değerlendirmektir. Çalışmanın sıfır hipotezi gruplar arasında bir farklılık olmayacağı yönündedir.

5.2 Gereç ve Yöntemin Tartışılması

Çalışmamızda çift çene ortognatik cerrahi hastalarından alınan BT görüntülerinden elde edilen 2 boyutlu görüntüler AudaxCeph, OrthoDx, WebCeph programları (derin öğrenme yapay zeka algoritmasına sahip tam otomatik dijital sefalometrik analiz programları) ile Nemoceph programı (bilgisayar destekli dijital sefalometrik analizi) ve 3 boyutlu analiz programı olan Nemoceph 3D (surgeryFAB) ile karşılaştırılmıştır. Nemoceph ve Nemoceph 3D (Surgery FAB) programları ortodonti pratiğinde sıklıkla kullanılmaktadır ve birçok çalışmada etkinliği değerlendirilmiştir [165-168].

Dijital ortognatik cerrahi planlaması için BT görüntüleri alınan hastalardan onam alınarak BT görüntüleri çalışma grubuna dahil edilmiştir. İşaretlenme aşamasında görüntüler sagittal kesitlerde değerlendirilmiştir. Görüntülerin 3 boyutlu olarak incelenmesiyle tespit edilen ideal median kesitte kafatasında orta hatta bulunan anatomik noktalar işaretlenmiştir. Ramirez ve arkadaşları yaptıkları çalışmada sağ taraftaki tomografik dilimlerden yapılan ölçümlerin sola göre istatistiksel olarak daha büyük farklılıklar gösterdiğini tespit etmişlerdir[169]. Bu çalışmaya dayanarak kafatasının her iki tarafında da bulunan anatomik noktalarda standardizasyon olması adına sol taraf seçilmiştir.

Ristau ve arkadaşları[170] yaptıkları çalışmada radyografik görüntüler ile ilgili herhangi bir olağandışı durumun, yapay zeka yazılımının anatomik nokta belirleme yeteneğini etkileyebileceğini belirtmişlerdir. Anormalliklerle ilişkili sefalometriler değerlendirilirken yapay zeka programlarının güvenilirliğini değerlendirmek için daha fazla çalışma gerektiğini

aktarmışlardır. Derin öğrenme sistemiyle çalışan tam otomatik sefalometrik analiz programları eğitim verisi miktarı arttıkça daha doğru sonuçlar vermektedir.

Ortognatik cerrahi hastaları gibi normalden uzaklaşmış değerlere sahip hastalarda anatomik noktaları işaretleyebilme kapasitesini ölçen bir çalışma literatürde bulunmamaktadır.

BT'den elde edilen 3 boyutlu görüntülerde birbirlerine paralel ışınlar ile magnifikasyona sebep olmayan görüntüler elde edilmektedir[152]. Yitschaky ve arkadaşları yaptıkları çalışmada sefalometrik görüntüleri dijital sefalostat makinesi ile almışlardır[163]. Çizimler sonrası %9 magnifikasyon oranını hesaplayarak ölçümlerden çıkarmışlardır. Çalışmamızda BT'den elde edilen 3 boyutlu görüntülerin sagittal kesitlerinin üst üste bindirilmeleri ile oluşturulan 2 boyutlu görüntüler elde edilmiştir. Böylece noktasal bir kaynaktan çıkan X ışınlarının birbirlerine paralel olmaması ve diverjan bir şekilde yayılması nedeniyle görüntüde meydana gelen genişleme önlenmiş olur[37].

3 boyutlu BT rekonstrüksiyonlarının sefalometrik ölçümleri bilgisayar destekli dijital sefalometrik analizde manuel işaretleme işlemi aynı araştırmacı tarafından gerçekleştirilmiştir. Kılınç ve arkadaşları yöntem hatasını değerlendirmek için, her ölçüm grubundan 20 örneği başlangıç ölçümlerinden 4 hafta sonra tekrar ölçmüşlerdir[164]. Bizim çalışmamızda da ilk işaretlemeden 4 ay sonra yine aynı araştırmacı tarafından rastgele seçilen 3 boyutlu BT rekonstrüksiyonlarının sefalometrik ölçümleri 20 sefalometrik görüntünün anatomik noktaları tekrar işaretlenmiştir. Aynı gözlemcinin aynı yöntemle farklı zamandaki iki ölçümü arasındaki ICC 0,98 olarak bulunmuş ve gözlemci içi güvenilirliğinin yüksek olduğu tespit edilmiştir[155]. Böylece bilgisayar destekli dijital sefalometrik analiz ile yapay zeka algoritmasına sahip programlardan elden edilen ölçümlerin kıyaslanacağı 'kesin referans' değerler elde edilmiştir. Kunz ve arkadaşları yaptıkları çalışmada 2 boyutlu sefalometrik ölçümleri 12 deneyimli ortodontist tarafından el ile çizilerek bulmuş ve ortalamalarını insan altın standardı olarak belirleyip tam otomatik sefalometrik analiz programlarını karşılaştırmışlardır[171]. Bizim çalışmamızda insan altın standardı 3 boyutlu BT rekonstrüksiyonlarının sefalometrik ölçümleri görüntülerin tek bir araştırmacı tarafından işaretlenmesi ile elde edilmiştir.

AudaxCeph, OrthoDx ve WebCeph programlarının otomatik işaretlemesinden sonra araştırmacı, programların işaretleme sırasında hata yaptığını düşündüğü anatomik noktalara müdahale

etmemiştir. Literatürde yapay zeka algoritmasına sahip analiz programlarında sefalometrik noktalara müdahale etmeyen çalışmalar mevcuttur[164, 172, 173]. Bu yöntemle yapay zeka algoritmasına sahip analiz programlarının doğruluğunu ölçmek amaçlanmıştır.

Çalışmamızda 50 BT görüntüsü ve yine aynı görüntülerden elde edilen 2 boyutlu sefalometrik radyografi 5 farklı analiz programında incelenmiştir. Gruplar sırasıyla; Nemoceph 3D (SurgeryFAB), Nemoceph 2D, AudaxCeph, OrthoDx ve WebCeph programlarından oluşmaktadır.

Çalışmamızda piyasada bulunan AudoxCeph, OrthoDx ve WebCeph programlarını kullanmamızın sebebi bu programların derin öğrenme modelini kullanması ve ortodonti kliniklerinde yaygın olarak kullanılmasıdır.

Literatürde yapay zeka algoritmasına sahip analiz programları ile bilgisayar destekli analiz programlarını karşılaştıran çalışmalardan Çoban ve arkadaşları[172] yaptıkları çalışmada 105, Meriç ve arkadaşları[174] yaptıkları çalışmada 40, Kumar ve arkadaşları[166] yaptıkları çalışmada 100, Kılınç ve arkadaşları[164] yaptıkları çalışmada 110, Jeon ve Lee'nin[139] yaptıkları çalışmada 35, Mosleh ve arkadaşları[175] yaptıkları çalışmada 30 dijital sefalometrik radyografi incelemiştir. Kunz ve arkadaşları[171] 4 farklı tam otomatik sefalometrik analizi, konvansiyonel sefalometrik analizler ile karşılaştırdıkları çalışmada 50 adet sefalometrik görüntüyü kullanmışlardır. Bizim çalışmamızda 50 adet BT görüntüsü ile edilen sefalometrik ölçümler altın standart olarak kabul edilmiş ve bilgisayar destekli dijital sefalometrik analiz programları ve tam otomatik sefalometrik analizler ile karşılaştırarak örneklem grupları oluşturulmuştur.

Ayrıca 3 boyutlu sefalometrik analiz programları ile bilgisayar destekli dijital sefalometrik analizleri ile karşılaştıran çalışmalardan Oded Yitschaky ve arkadaşları [163] yaptıkları çalışmada 10, Natalia Zamora ve arkadaşları[162] yaptıkları çalışmada 8, W. Bholsithi ve arkadaşları[176] yaptıkları çalışmada 40 adet 3 boyutlu görüntüyü karşılaştırmışlardır. Çalışmamızda 50 adet BT görüntüsünün 3 boyutlu BT rekonstrüksiyonlarının sefalometrik analiz programında işaretlenmesi ile elde edilen sefalometrik ölçümler, yapay zeka algoritmasına sahip programların ve bilgisayar destekli dijital sefalometrik programların üzerinde gerçekleştirdiğimiz ölçümler ile karşılaştırılmıştır.

Çalışmamızda 6'sı yumuşak dokuda 19'u sert dokuda bulunmak üzere toplam 25 nokta kullanılmıştır. Çalışmamızda kullanılan anatomik noktalar pratikte sıklıkla kullanılan parametrelerden seçilmiştir. Ayrıca farklı araştırmalarda Orbitale, Porion, Gonion gibi belirlenmesi zor olan anatomik noktaların da araştırmamızda işaretlenmesine dikkat edilmiştir [60, 177, 178].

Literatür incelendiğinde Meriç ve arkadaşlarının yürüttükleri çalışmada [174] 8 açısal, 4 doğrusal olmak üzere toplam 12, Jeon and Lee'nin yürüttükleri çalışmada [139] 15 iskeletsel, 9 dişsel ve 2 yumuşak doku olmak üzere toplam 26, Çoban ve arkadaşları[172] yaptıkları çalışmada 10 doğrusal ve 12 açısal olmak üzere toplam 22, Kılınç ve arkadaşları[164] yaptıkları çalışmada 4 doğrusal ve 7 açısal olmak üzere 11 ölçüm değerlendirmişlerdir. Çalışmamızda üniversitemizde standart olarak kullanılan analizde 17 açısal, 15 çizgisel, 1 oransal olmak üzere toplam 33 sefalometrik ölçüm değerlendirilmiştir.

5.3 Bulguların Tartışılması

Çalışmamızda, NemoCeph 3D (Surgery FAB) ile NemoCeph 2D dijital analiz programlarında yapılan ölçümler karşılaştırıldığında, SN-PP, U1/SN, U1/NA ve L1-NB ölçümlerinde istatistiksel anlamlı farklılıklar bulunmuştur. Daha önceki çalışmalarda istatistiksel olarak anlamlı olan ancak 2 ölçüm biriminden (milimetre veya derece) küçük olan bir farkın klinik olarak kabul edilebilir sınırlar içinde olduğu belirtmişlerdir [61, 172]. İstatistiksel olarak fark bulunan ölçümlerimiz olmasına rağmen hiçbir ölçüm klinik olarak anlamlı değerlendirilecek kadar farklı bir sonuca sahip değildir. Meriç ve Naoumova yaptıkları çalışmada hem konvansiyonel hem de dijital yaklaşımlarda hem maksiller hem de mandibular kesici dişlerin kök sınırlarını kemikte görmenin zorluğundan kaynaklı hatalar yapılabileceğini belirtmişlerdir[174]. Bu çalışma sonucu bizim çalışmamızda klinik olarak anlamsız ama istatistiksel olarak anlamlı fark bulunan ölçümleri açıklayabilir.

Çalışmamız 3B görüntülerin rekonstrüksiyonu üzerinde yapılan ölçümlerin, geleneksel 2B dijital sefalometrik analiz ölçümlerine klinik olarak benzer sonuçlar verdiğini göstermiştir. Yitschaky ve arkadaşları yaptıkları çalışmada 3 boyutlu rekonstrüksiyon ile 2 boyutlu sefalometrik ölçümleri karşılaştırdıklarında sella turcica bağımlı ölçümler dışında anlamlı bir fark bulmamışlardır [161]. Yitschaky ve arkadaşları 2 boyutlu sefalometrik görüntüleri %9 büyötmeye sahip bir sefalostat

makinesiyle (Cranex, Soredex, Tuusula, Finlandiya) almışlardır. Bizim çalışmamızda 2 boyutlu sefalometrik görüntüler magnifikasyona sebep olmayan paralel ışınlarla oluşan BT görüntülerinin üst üste bindirilmesiyle oluşturulmuştur. 2 boyutlu elde edilen sefalometrik görüntülerde daha net anatomik nokta tespiti yapılabilmesinden dolayı, 3 boyutlu rekonstrüksiyon ile elde edilen 2 boyutlu sefalometrik analiz ölçümleri daha yakın sonuçlar vermektedir. Bu durum Yitschaky ve arkadaşlarının yaptıkları çalışma ile olan farkı açıklayabilir. Natalia Zamora ve arkadaşları yaptıkları çalışmada 8 hastada inceledikleri 13 ölçümün hiçbirinde istatistiksel olarak anlamlı bir fark bulmamışlardır [160].

Perrotti ve arkadaşları yaptıkları çalışmada 2 boyutlu sefalometrik görüntüler ile 3 boyutlu görüntüler arasında yumuşak doku değerlerini karşılaştırmış ve istatistiksel bir fark bulmamışlardır[179]. Bizim sonuçlarımızda da bu çalışmaların sonuçlarına uygun olarak klinik olarak anlamlı bir fark bulunmamıştır.

3D ile AudoxCeph programlarında yapılan ölçümler karşılaştırıldığında N-A, N-Pog, Y aksı açısı, GoMe/SN, GoGn/SN, arka-ön yüz yüksekliği oranı, IMPA, üst dudak protrüzyonu ve alt dudak protrüzyonu istatistiksel olarak anlamlı bulunmuştur. GoGn/SN ve GoMe/SN dışındaki diğer farklar klinik olarak anlamlı bulunmuştur. Bu ölçümler dışındaki ölçümlerde anlamlı bir fark bulunamamıştır. Çalışmamızda değerlendirilen 33 sefalometrik ölçümün 9 tanesi istatistiksel olarak, 7 tanesi klinik olarak farklı bulunmuştur. Ristau ve arkadaşları yaptıkları çalışmada AudoxCeph ile dijital sefalometrik analizleri karşılaştırmışlardır[170]. Noktalar yapay zeka tarafından seçilmiş ve müdahale edilmemiştir. Porion noktası dışında klinik olarak anlamlı bir nokta bulmamışlardır ayrıca Orbitale, U1 apex ve L1 apex gibi noktaları güvenilir bulmuşlardır. Ancak yaptıkları çalışmada hastalar özenle seçilmiştir, kraniyofasiyal anomalisi olan hastalar dışlanmıştır ve yumuşak doku içeren anatomik noktaları kullanmamışlardır. Çalışmamızda IMPA ve Y aksı açısı ölçümleri, içerdikleri anatomik noktalar sebebi ile bu çalışmayla tutarlı bulunmuştur. Çalışmamızda bu çalışmadan daha fazla ölçümde istatistiksel farklılık çıkmasının nedeni değerlendirilen anatomik nokta sayısının fazla olması ve örneklem grubunun cerrahi hastalardan oluşması olabilir. Kunz ve arkadaşları AudoxCeph programı ve el ile çizilen sefalometrik ölçümleri karşılaştırdıkları çalışmada değerlendirilen 9 ölçümdeki dental ölçümler dışında tüm iskeletsel değerlerde istatistiksel olarak anlamlı farklılık bulmuşlardır. Özellikle Gonion noktasını içeren ölçümlerde dikkatli olunması gerektiğini belirtmişlerdir[171].

Bizim çalışmamızda da GoGn/SN, GoMe/SN ve IMPA değerlerinde istatistiksel olarak anlamlı farklar bulunmuştur ve Kuntz ve arkadaşlarının çalışması ile uyumludur.

3D ile OrthoDx programlarında yapılan ölçümler karşılaştırıldığında SNB, N-A, GoMe/SN, SN/PP, FMA, arka yüz yüksekliği, arka-ön yüz yüksekliği oranı, alt ön yüz yüksekliği, ön kafa kaidesi uzunluğu, Co-A, Co-Gn, Go-Me, U1/OP, IMPA ve L1/NB anlamlı bulunmuştur. Bu ölçümler dışındaki ölçümlerde anlamlı bir fark bulunamamıştır. SNB, GoMe/SN, Ön kafa kaidesi uzunluğu ve Alt ön yüz yüksekliği haricinde diğer farklar klinik olarak anlamlı bulunmuştur. Çalışmamızda değerlendirilen 33 sefalometrik ölçümün 15 tanesinde istatistiksel olarak 11 tanesinde klinik olarak anlamlı fark bulunmuştur. Duran ve arkadaşları, WebCeph ve OrthoDx programlarını, bilgisayar destekli dijital sefalometrik analiz programı ile karşılaştırmışlardır. Açısal ölçümlerin iyi ve orta düzeyde tutarlılık gösterdiğini, iskeletsel lineer ve yumuşak doku ölçümlerinde ise zayıf tutarlılık gösterdiğini bulmuşlardır[180]. Bizim çalışmamızda da N-A, Arka yüz yüksekliği, Alt ön yüz yüksekliği, Ön kafa kaidesi uzunluğu, Co-A, Co-Gn, Go-Me iskeletsel lineer ölçümlerinde istatistiksel olarak farklar bulunmuştur ve bu çalışmalar ile tutarlıdır. Ancak çalışmamızda Duran ve arkadaşlarının yaptıkları çalışmadan farklı olarak açısal ölçümlerde de istatistiksel olarak anlamlı farklar bulunmuştur. Bunun sebebi çalışmamızın örneklem grubu olan cerrahi hastalarının anatomik olarak normalden sapmalarının fazla olması olabilir.

3D ile WebCeph programlarında yapılan ölçümler karşılaştırıldığında SNA, SNB, Y aksı açısı, SN/PP, SN/GoGn, FMA, ön kafa kaidesi uzunluğu, Go-Me, IMPA, nasolabial açı, üst dudak protrüzyonu ve alt dudak protrüzyonu değerlerinde istatistiksel olarak anlamlı farklar bulunmuştur. Bu ölçümler dışındaki ölçümlerde anlamlı bir fark bulunamamıştır. SNA ve Ön kafa kaidesi uzunluğu ölçümleri dışındaki diğer farklar klinik olarak da anlamlıdır. Çalışmamızda değerlendirilen 33 sefalometrik ölçümün 12 tanesi istatistiksel olarak 10 tanesi klinik olarak anlamlı bulunmuştur. Kunz ve arkadaşları yaptıkları çalışmada WebCeph programı ve el ile çizilen sefalometrik ölçümleri karşılaştırmışlar ve SNA ve SNB için ortalama doğruluk ve ortalama hassasiyet tespit etmişlerdir. Bununla birlikte SN-PP için orta doğruluk düşük hassasiyet ve SN/MeGo ile yüz yüksekliği oranı için düşük ortalama doğruluk düşük hassasiyet bulmuşlardır[171]. Bizim çalışmamızda SNA, SNB ve SN/PP anlamlı olarak farklı bulunmuştur ve çalışmayla uyumludur. SN/MeGo ve yüz yüksekliği oranının bizim çalışmamızda anlamlı

olmamasının sebebi BT'den elde edilen 2 boyutlu görüntüler ile karşılaştırılmasıyla açıklanabilir. Dental olarak alt ve üst kesicilerin eğimlerinin orta doğrulukta olduğunu ve çok düşük hassasiyeti olduğunu bulmuşlardır. Bizim çalışmamızda IMPA ölçümlerinin istatistiksel olarak anlamlı olması bu çalışma ile tutarlı bulunmuştur.

Kunz ve arkadaşları toplamda 9 ölçümü değerlendirirken bizim çalışmamızda 33 sefalometrik ölçüm değerlendirilmiştir. Çalışmamızda değerlendirilen ölçüm sayısının diğer çalışmalara göre fazla olması, klinik olarak anlamlı sonucun çıkmasını açıklayabilir. Kılınç ve arkadaşları yaptıkları çalışmada CephNinja, WebCeph ve konvansiyonel sefalometrik ölçümleri karşılaştırmışlardır. SNA, SNB, SN/MP açısı, U1/SN Açısı, L1-NB(mm), E line-üst dudak değerleri karşılaştırıldığında üç yöntem arasında istatistiksel olarak anlamlı farklılık bulmuşlardır[164]. Bizim çalışmamızda da SNA, SNB, üst dudak protrüzyonu istatistiksel olarak farklı bulunmuştur ve bu çalışma ile tutarlıdır.

Meriç ve Naoumova, çalışmalarında Dolphin Imaging CephNinja kullanılarak yapılan uygulama destekli izleme ve CephX ile web tabanlı tamamen otomatik izlemeyi karşılaştırmışlardır. Tüm kesici dişlerle ilgili ölçümlerin istatistiksel olarak anlamlı farklılıklar gösterdiğini bulmuşlardır. Bu farklılıkların hem konvansiyonel hem de dijital yaklaşımlarda hem maksiller hem de mandibular kesici dişlerin kök sınırlarını kemikte görmenin zorluğundan kaynaklanabileceğini belirtmişlerdir[174]. Çalışmamızda, IMPA ölçümünde tüm tam otomatik sefalometrik ölçüm yöntemlerinde, istatistiksel ve klinik olarak anlamlı bir fark bulunmuştur. Bulgularımız, Meriç ve Noumova'nın bulgularıyla tutarlıdır.

Amerikan Ortodonti Kurulu'nun tanımına göre mandibular düzlem (GoMe), 'Oluşturulmuş Gonion'dan Menton'a bir düzlem'dir. Bu değer sonularındaki farkın nedeni, gonion noktasının her sefalogram için oluşturulan bir nokta olmasıdır. Kunz ve arkadaşları Gonion anatomik noktası tespitinde yapay zeka analiz programlarının yetersiz olduğunu belirtmişlerdir[171]. Çalışmamızda tüm tam otomatik sefalometrik ölçüm yöntemlerinde Gonion noktası içeren ölçümlerde istatistiksel ve klinik olarak anlamlı bir fark bulunmuştur.

Zamrik ve İşeri, konvansiyonel ve dijital yöntemler arasında üst dudak ile S değerlerinin ölçümünde bir tutarsızlık bildirmişlerdir[181]. Kılınç ve arkadaşları yaptıkları çalışmada E Hattı-Üst Dudak (mm) ölçümleri açısından yöntemler arasında istatistiksel olarak anlamlı bir fark

bulmuşlardır[164]. Çalışmamızda da bu çalışmalar ile uyumlu olarak yumuşak doku ölçümlerinde istatistiksel anlamlı farklar bulunmuştur.

Ayrıca çalışmamızda alt dudak protrüzyon ölçümlerinde de istatistiksel anlamlı farklar bulunmuştur, bunun sebebi alınan BT görüntülerinin hasta yatay pozisyonunda alınması sebebiyle yumuşak doku tonusunda farklılıklar oluşmasıyla ve ameliyat hastalarında alt çene pozisyonlarının fazla değişkenlik göstermesi sebebiyle normalden uzak pozisyonlara ulaşması olabilir.

Yapılan ölçümler Nemoceph 3D(Surgery FAB) ile tek karşılaştırıldıktan sonra, NemoCeph3D (Surgery FAB) ile ölçülen değerler arasındaki farklar kaydedilmiştir. Kaydedilen farklar ile elde edilen 4 grup da NemoCeph 2D, Audox, OrthoDx ve Webceph kendi aralarında karşılaştırılmıştır.

Çalışmamızda, yöntemler arasında ANB açısında istatistiksel olarak anlamlı bir fark bulunmamıştır. Bu sonuç, Mohan ve arkadaşları[182] ve Kılınç ve arkadaşlarının [164] bulgularıyla tutarlıdır. Çalışmamızda NemoCeph 2D, Audox, OrthoDx ve WebCeph grupları arasında SNA ve SNB değerlerinde farklılıklar olsa da hastanın iskeletsel sagittal anomalisini belirlerken ana veri olarak kabul ettiğimiz ANB değerleri açısından istatistiksel bir fark olmaması, kümülatif sonuçlar açısından dikkate alınması gereken bir konudur.

Literatür incelendiğinde Anuwongnukroh ve arkadaşları tamamen otomatik bir sefalometrik analiz programı (Carestream Dental, versiyon 6.14) üzerinde çalışmış ve tamamen otomatik analizlerin, Porion ve azı dişleri gibi çift taraflı yapıların referans noktalarındaki hatalar nedeniyle manuel analiz kadar güvenilir olmadığını bulmuşlardır[158]. Benzer şekilde, Leonardi ve arkadaşları sefalogramların otomatik olarak işaretlenmesi için kullanılan teknikler üzerine bir sistematik inceleme yapmışlar ve incelemelerinde, otomatik referans noktası tespitindeki hataların manuel yerleştirmeden daha fazla olduğunu ve otomatik izlenen sefalometrik izlemelerin klinik kullanım için yeterince doğru olmadığını bulmuşlardır[142].

Öte yandan Lindler ve arkadaşları yaptıkları çalışmada deneyimli ortodontistlere benzer ve %84,7 doğrulukla referans noktası belirleyen yapay zeka analiz programlarını geliştirmişlerdir[146]. Ayrıca Hwang ve arkadaşları You-Only-Look-Once versiyon 3 (YOLOv3) adlı otomatik referans noktası tespit sistemini manuel tespit ile karşılaştırmış ve YOLOv3'ün tecrübeli ortodontistler kadar doğru olduğunu bulmuşlardır[141].

Bulatavo ve arkadaşları Ceppro DDH Inc yazılımını incelemiş ve yapay zekanın on altı noktanın on ikisini insan operatörlerden 2 mm farkla doğru şekilde işaretlediğini bulmuşlardır[147].

Bizim çalışmamızda yapılan ölçümler sonucunda 4 yöntemi karşılaştırdığımızda NemoCeph 2D sefalometrik analiz programında ANB açısı dışındaki çoğu ölçümde, istatistiksel anlamlı olarak diğer yöntemlere göre daha az sapma bulunmuştur. Bu anlamlı farkı bulmamızın sebebi yapay zeka tabanlı sefalometrik analiz programlarının çalışma grubumuz olan ortognatik cerrahi hastalarında yeterince veriye sahip olmaması olabilir. Bu sebeple diğer çalışmalarda diğer yöntemlere daha yakın bulunan yapay zeka analiz programlarının, çalışmamızda istatistiksel olarak daha farklı sonuçlar bulunmuş olabilir.

Aşağıdaki kliniğimizde tedavi olan bir hastanın fotoğrafında Python OpenCV face align açık kütüphanesinde bulunan veriler ile işaretlenen anatomik noktadaki sapmalar görülmektedir. Ölçümlerimizde kullanılan Prn, Sn, A', Ls, Li, Pog' noktalarını yeterli tespit edemediği görülmektedir. Favaedi ve arkadaşları yaptıkları çalışmada yapay zeka kullanılarak yumuşak doku tespitinin çok güç olduğunu ve hatalara açık olduğunu belirtmişlerdir[183]. Bu durum çalışmamızda bulunan farklı tam otomatik sefalometrik analiz programlarının yumuşak doku ölçümlerinde anlamlı farklar bulmasını açıklamaktadır. Ayrıca alınan BT görüntülerinin hasta yatay pozisyonunda alınması sebebiyle yumuşak doku tonusunda farklılıklar oluşmasıyla ve ameliyat hastalarında alt çene pozisyonlarının fazla değişkenlik göstermesi sebebiyle normalden uzak pozisyonlara ulaşması olabilir.



Şekil 5.1: Python OpenCV face align açık kütüphanesinde açık kütüphanesinde bulunan veriler ile işaretlenen yumuşak doku anatomik noktaları

6 SONUÇLAR VE ÖNERİLER

NemoCeph 3D(Surgery FAB) programında yapılan ölçümler NemoCeph (2D) programı ve yapay zeka programları AudaxCeph, OrthoDx ve WebCeph ölçümleri ile ayrı ayrı karşılaştırılmıştır.

3D ile 2D Nemoceph programlarında yapılan ölçümler karşılaştırıldığında SN-PP, U1/SN, U1/NA ve L1-NB ölçümlerinde istatistiksel olarak anlamlı farklar bulunmuştur.

3D ile Audoxeph programlarında yapılan ölçümler karşılaştırıldığında N-A, N-Pog, Y aksı açısı, GoMe/SN, GoGn/SN, arka- ön yüz yüksekliği oranı, IMPA, üst dudak protrüzyonu ve alt dudak protrüzyonu ölçümlerinde istatistiksel olarak anlamlı farklar bulunmuştur.

3D ile OrthoDx programlarında yapılan ölçümler karşılaştırıldığında SNB, N-A, GoMe/SN, SN/PP, FMA, arka yüz yüksekliği, arka-ön yüz yüksekliği Oranı, alt ön yüz yüksekliği, ön kafa

kaidesi uzunluđu Co-A, Co-Gn, Go-Me, U1/OP, IMPA ve L1/NB ölçümlerinde istatistiksel olarak anlamlı farklar bulunmuştur.

3D ile WebCeph programlarında yapılan ölçümler karşılaştırıldığında SNA, SNB, Y aksı açısı, SN/PP, SN/GoGn, FMA, ön kafa kaidesi uzunluđu, Go-Me, nasolabial açı, üst dudak protrüzyonu ve alt dudak protrüzyonu ölçümlerinde istatistiksel olarak anlamlı farklar bulunmuştur.

Yapılan ölçümler Nemoceph 3D(Surgery FAB) ile tek karşılaştırıldıktan sonra, NemoCeph 3D(Surgery FAB) ile ölçülen değerler arasındaki farklar kaydedilmiştir. Kaydedilen farklar ile elde edilen 4 grup da NemoCeph 2D, Audox, OrthoDx ve Webceph kendi aralarında karşılaştırılmıştır.

ANB değeri ($p=0,061$) dışındaki tüm ölçümlerde gruplar arasında istatistiksel olarak anlamlı farklılık bulunmuştur ($p<0,05$). ANB dışındaki tüm ölçümlerde NemoCeph 2D, NemoCeph 3D programına en yakın sonuçları vermiştir.

Yapay zeka tabanlı sefalometrik analiz programlar bir referans noktası tespiti için derin öğrenme tekniklerine veya konvolüsyonel sinir ağlarına dayanan yapay zekayı kullanır[171]. Bu modellerde noktaların tespiti için çok sayıda görüntünün yapay zeka tarafından işlenmesi gerekmektedir. Ancak çalışmamızda yalnızca ortognatik cerrahi öncesi alınan görüntüler değerlendirilmiştir. Diğer çalışmalarda diğer yöntemlere daha yakın bulunan yapay zeka analiz programlarının çalışmamızda istatistiksel olarak anlamlı olacak şekilde farklı bulunmuştur. Bu sebeple ortognatik cerrahi hastalarında tam otomatik sefalometrik analizler kullanılırken manuel olarak düzeltme önerilir.

Literatürü incelediğimizde tam otomatik sefalometrik analiz programlarında incelenen röntgenlerin büyük bir kısmı benzer norm aralıklarındadır. Daha önce yapılan çalışmalarda yapay zeka programlarında benzer verilerin işlenmesi sonucu veri tekrarı oluştuđu gösterilmiştir. Bununla birlikte benzer norm aralıkları dışında verilerin işlenmesi durumunda bias oluştuđu da belirtilmiştir[94]. Bu nedenle çalışmamızda tam otomatik sefalometrik analiz programlarında incelenen norm değerlendiren uzak ortognatik cerrahi hastalarının ölçümlerinde düzensizlik gözlenmiştir. Daha sağlıklı veri işlenmesi amacıyla tam otomatik sefalometrik analiz programlarında ön sınıflandırma modülü kullanılması önerilir.

Çalışmamızda bütün işaretlemeler tek bir araştırmacı tarafından işaretlenmiştir. İleride yapılacak olan çalışmalarda birden fazla araştırmacı tarafından işaretlemeler yapılabilir. Çizilen 3 boyutlu sefalometrik analizlerde orta hatta bulunan anatomik noktalar 3 boyutlu olarak seçilen ideal tek bir sagittal kesit üzerinde işaretlenmiştir. Bundan sonraki çalışmalarda farklı programlarda 3 boyutlu işaretlemeler yapılabilir.

Çalışma grubumuz 50 hasta ile sınırlıdır. Daha sonraki çalışmalarda çalışma grubu sayısı artırılması ayrıca sınıf II ve sınıf III cerrahi gruplarının ayrı ayrı değerlendirilmesi önerilebilir.

Piyasada bulunan sadece 3 tam otomatik sefalometrik analiz değerlendirilmiştir. İleriki çalışmalarda daha fazla yapay zeka temelli tam otomatik sefalometrik analiz programları kullanılabilir.

KAYNAKÇA

1. Broadbent, B. H. (1931). A new x-ray technique and its application to orthodontia. *The angle orthodontist*, 1(2), 45-66.
2. Sandler, P. (1988). Reproducibility of cephalometric measurements. *British journal of orthodontics*, 15(2), 105-110.
3. Bruntz, L. Q., Palomo, J. M., Baden, S. ve Hans, M. G. (2006). A comparison of scanned lateral cephalograms with corresponding original radiographs. *American Journal of Orthodontics and Dentofacial Orthopedics*, 130(3), 340-348.
4. Silva, J., Castilho, J., Matsui, R. H., Matsui, M. Y. ve Gomes, M. F. (2011). Comparative study between conventional and digital radiography in cephalometric analysis. *J Health Sci Inst*, 29(1), 19-22.
5. Chen, S.-K., Chen, Y.-J., Yao, C.-C. J. ve Chang, H.-F. (2004). Enhanced speed and precision of measurement in a computer-assisted digital cephalometric analysis system. *The Angle Orthodontist*, 74(4), 501-507.
6. Naoumova, J. ve Lindman, R. (2009). A comparison of manual traced images and corresponding scanned radiographs digitally traced. *The European Journal of Orthodontics*, 31(3), 247-253.
7. Albarakati, S., Kula, K. ve Ghoneima, A. (2012). The reliability and reproducibility of cephalometric measurements: a comparison of conventional and digital methods. *Dentomaxillofacial Radiology*, 41(1), 11-17.
8. Cardillo, J. ve Sid-Ahmed, M. A. (1994). An image processing system for locating craniofacial landmarks. *IEEE transactions on medical imaging*, 13(2), 275-289.
9. Grau, V., Alcaniz, M., Juan, M., Monserrat, C. ve Knoll, C. (2001). Automatic localization of cephalometric landmarks. *Journal of Biomedical Informatics*, 34(3), 146-156.
10. Davis, D. ve Taylor, C. (1991). A blackboard architecture for automating cephalometric analysis. *Medical Informatics*, 16(2), 137-149.
11. Schwendicke, F., Chaurasia, A., Arsiwala, L., Lee, J.-H., Elhennawy, K., Jost-Brinkmann, P.-G., ve ark. (2021). Deep learning for cephalometric landmark detection: systematic review and meta-analysis. *Clinical oral investigations*, 25(7), 4299-4309.
12. **Udupa, J. K. ve Herman, G. T.** (1999). *3D imaging in medicine*. CRC press.
13. Seeram, E. (1997). 3-D imaging: basic concepts for radiologic technologists. *Radiologic technology*, 69(2), 127-149.
14. Farkas, L. G., Posnick, J. C. ve Hreczko, T. M. (1992). Anthropometric growth study of the head. *The Cleft Palate-Craniofacial Journal*, 29(4), 303-308.
15. Dimaggio, F. R., Ciusa, V., Sforza, C. ve Ferrario, V. F. (2007). Photographic soft-tissue profile analysis in children at 6 years of age. *American journal of orthodontics and dentofacial orthopedics*, 132(4), 475-480.
16. Canigur Bavbek, N., Balos Tuncer, B. ve Tortop, T. (2014). Soft tissue alterations following protraction approaches with and without rapid maxillary expansion. *Journal of Clinical Pediatric Dentistry*, 38(3), 277-283.
17. Zhao, H., Du, H., Li, J. ve Qin, Y. (2013). Shadow moiré technology based fast method for the measurement of surface topography. *Applied optics*, 52(33), 7874-7881.
18. Wong, J. Y., Oh, A. K., Ohta, E., Hunt, A. T., Rogers, G. F., Mulliken, J. B. ve Deutsch, C. K. (2008). Validity and reliability of craniofacial anthropometric measurement of 3D digital photogrammetric images. *The Cleft Palate-Craniofacial Journal*, 45(3), 232-239.

19. Edler, R., Wertheim, D. ve Greenhill, D. (2003). Comparison of radiographic and photographic measurement of mandibular asymmetry. *American journal of orthodontics and dentofacial orthopedics*, 123(2), 167-174.
20. McCarthy, J. G. ve Karron, D. B. (1988). Three-dimensional input of body surface data using a laser light scanner. *Annals of plastic surgery*, 21(1), 38-45.
21. von Cramon-Taubadel, N. (2018). Craniometry. *The Encyclopedia of Archaeological Sciences*, 1-4.
22. Allen, W. I. (1963). Historical aspects of roentgenographic cephalometry. *American Journal of Orthodontics*, 49(6), 451-459.
23. Bjork, A. (1947). The face in profile: an anthropological X-ray investigation on Swedish children and conscripts.
24. Athanasiou, A. E. (1995). Orthodontic cephalometry. (No Title).
25. Pacini, A. (1922). Roentgen ray anthropometry of the skull. *J Radiol*, 3(8), 322-331.
26. McCowen, C. S. (1923). Usefulness of an X-ray Machine in Orthodontia. *International Journal of Orthodontia, Oral Surgery and Radiography*, 9(3), 230-235.
27. Carrea, G. (1924). Les radiofacies a profile delinee en orthodontometrie. *Semaine Dent*, 6, 416-419.
28. Durão, A. R., Algerban, A., Ferreira, A. P. ve Jacobs, R. (2015). Influence of lateral cephalometric radiography in orthodontic diagnosis and treatment planning. *The Angle Orthodontist*, 85(2), 206-210.
29. Nijkamp, P. G., Habets, L. L., Aartman, I. H. ve Zentner, A. (2008). The influence of cephalometrics on orthodontic treatment planning. *The European Journal of Orthodontics*, 30(6), 630-635.
30. Uzel, İ. (2000). Enacar A. *Ortodontide sefalometri*, 2, 3-18.
31. Jacobson, A. (1995). Radiographic cephalometry: from basics to videoimaging. (No Title).
32. **Ülgen, M.** (2000). *Ortodonti: anomaliler, sefalometri, etiloji, büyüme ve gelişim, tanı*. Yeditepe Üniversitesi.
33. Graber, T., Vanarsdall, R. ve Vig, K. (2005). Current principles and techniques. *Orthodontic Book, USA*, 607-611.
34. Hatton, M. ve Grainger, R. (1958). Reliability of measurements from cephalograms at the Burlington Orthodontic Research Centre. *Journal of Dental Research*, 37(5), 853-859.
35. Houston, W., Maher, R., McElroy, D. ve Sherriff, M. (1986). Sources of error in measurements from cephalometric radiographs. *The European Journal of Orthodontics*, 8(3), 149-151.
36. Houston, W. (1983). The analysis of errors in orthodontic measurements. *American journal of orthodontics*, 83(5), 382-390.
37. BERGERSEN, E. O. (1980). Enlargement and distortion in cephalometric radiography: compensation tables for linear measurements. *The Angle Orthodontist*, 50(3), 230-244.
38. Adams, G. L., Gansky, S. A., Miller, A. J., Harrell Jr, W. E. ve Hatcher, D. C. (2004). Comparison between traditional 2-dimensional cephalometry and a 3-dimensional approach on human dry skulls. *American journal of orthodontics and dentofacial orthopedics*, 126(4), 397-409.
39. Rino Neto, J., Paiva, J. B. d., Queiroz, G. V., Attizzani, M. F. ve Miasiro Junior, H. (2013). Evaluation of radiographic magnification in lateral cephalograms obtained with different X-ray devices: experimental study in human dry skull. *Dental Press Journal of Orthodontics*, 18, 17e11-17e17.

40. Baumrind, S. ve Frantz, R. C. (1971). The reliability of head film measurements: 1. Landmark identification. *American journal of orthodontics*, 60(2), 111-127.
41. MIDTGÅRD, J., BJÖRK, G. ve Linder-Aronson, S. (1974). Reproducibility of cephalometric landmarks and errors of measurements of cephalometric cranial distances. *The Angle Orthodontist*, 44(1), 56-61.
42. Baumrind, S. ve Frantz, R. C. (1971). The reliability of head film measurements: 2. Conventional angular and linear measures. *American journal of orthodontics*, 60(5), 505-517.
43. Mostafa, Y., El-Mangoury, N., Salah, A. ve Rasmy, E. (1990). Automated cephalographic soft-tissue analysis. *Journal of clinical orthodontics: JCO*, 24(9), 539-543.
44. Harorli, A., Akgül, M. ve Dağıstan, S. (2006). Diş hekimliği radyolojisi. *Ed Eser Ofset Matbaacılık*, 48-64.
45. Versteeg, C., Sanderink, G. ve Van Der Stelt, P. (1997). Efficacy of digital intra-oral radiography in clinical dentistry. *Journal of dentistry*, 25(3-4), 215-224.
46. Brennan, J. (2002). An introduction to digital radiography in dentistry. *Journal of orthodontics*, 29(1), 66-69.
47. Forsyth, D., Shaw, W. ve Richmond, S. (1996). Digital imaging of cephalometric radiography, part 1: advantages and limitations of digital imaging. *The Angle Orthodontist*, 66(1), 37-42.
48. Santoro, M., Jarjoura, K. ve Cangialosi, T. J. (2006). Accuracy of digital and analogue cephalometric measurements assessed with the sandwich technique. *American Journal of Orthodontics and Dentofacial Orthopedics*, 129(3), 345-351.
49. LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R., Hubbard, W. ve Jackel, L. (1989). Handwritten digit recognition with a back-propagation network. *Advances in neural information processing systems*, 2.
50. Carlos Quintero, J., Trosien, A., Hatcher, D. ve Kapila, S. (1999). Craniofacial imaging in orthodontics: historical perspective, current status, and future developments. *The Angle Orthodontist*, 69(6), 491-506.
51. Roden-Johnson, D., English, J. ve Gallerano, R. (2008). Comparison of hand-traced and computerized cephalograms: landmark identification, measurement, and superimposition accuracy. *American Journal of Orthodontics and Dentofacial Orthopedics*, 133(4), 556-564.
52. Näslund, E., Kruger, M., Petersson, A. ve Hansen, K. (1998). Analysis of low-dose digital lateral cephalometric radiographs. *Dentomaxillofacial Radiology*, 27(3), 136-139.
53. Forsyth, D., Shaw, W., Richmond, S. ve Roberts, C. (1996). Digital imaging of cephalometric radiographs, part 2: image quality. *The Angle Orthodontist*, 66(1), 43-50.
54. Parks, E. T. ve Williamson, G. F. (2002). Digital radiography: an overview. *J Contemp Dent Pract*, 3(4), 23-39.
55. Goaz, P. W. (1987). Oral radiology. *Principles and interpretation*, 533-540.
56. Rudolph, D., Sinclair, P. ve Coggins, J. (1998). Automatic computerized radiographic identification of cephalometric landmarks. *American Journal of Orthodontics and Dentofacial Orthopedics*, 113(2), 173-179.
57. Liu, J.-K., Chen, Y.-T. ve Cheng, K.-S. (2000). Accuracy of computerized automatic identification of cephalometric landmarks. *American Journal of Orthodontics and Dentofacial Orthopedics*, 118(5), 535-540.

58. Chen, Y.-J., Chen, S.-K., Chung-Chen Yao, J. ve Chang, H.-F. (2004). The effects of differences in landmark identification on the cephalometric measurements in traditional versus digitized cephalometry. *The Angle orthodontist*, 74(2), 155-161.
59. Tweed, C. H. (1946). The Frankfort-mandibular plane angle in orthodontic diagnosis, classification, treatment planning, and prognosis. *American journal of orthodontics and oral surgery*, 32(4), 175-230.
60. Gravely, J. ve Benzies, P. M. (1974). The clinical significance of tracing error in cephalometry. *British Journal of Orthodontics*, 1(3), 95-101.
61. İşman, O. (2010). İki farklı sefalometrik çizim ve analiz tekniğinin sert ve yumuşak doku analiz sonuçlarının karşılaştırılması.
62. Celik, E., Polat-Ozsoy, O. ve Toygar Memikoglu, T. U. (2009). Comparison of cephalometric measurements with digital versus conventional cephalometric analysis. *The European Journal of Orthodontics*, 31(3), 241-246.
63. Power, G., Breckon, J., Sherrieff, M. ve McDonald, F. (2005). Dolphin Imaging Software: an analysis of the accuracy of cephalometric digitization and orthognathic prediction. *International journal of oral and maxillofacial surgery*, 34(6), 619-626.
64. Richardson, A. (1981). A comparison of traditional and computerized methods of cephalometric analysis. *The European Journal of Orthodontics*, 3(1), 15-20.
65. Turner, P. ve Weerakone, S. (2001). An evaluation of the reproducibility of landmark identification using scanned cephalometric images. *Journal of orthodontics*, 28(3), 221-230.
66. Baumrind, S. ve Miller, D. M. (1980). Computer-aided head film analysis: the University of California San Francisco method. *American Journal of Orthodontics*, 78(1), 41-65.
67. Dana, J. M., Goldstein, M., Burch, J. G. ve Hardigan, P. C. (2004). Comparative study of manual and computerized cephalometric analyses. *Journal of clinical orthodontics: JCO*, 38(5), 293-296.
68. Doll, G. M., Zentner, A., Krummenauer, F. ve Gärtner, H. (2001). Reliability and validity of the Digigraph® 100 in orthodontic diagnosis. *Journal of Orofacial Orthopedics/Fortschritte der Kieferorthopädie*, 62, 116-132.
69. Hing, N. R. (1989). The accuracy of computer generated prediction tracings. *International journal of oral and maxillofacial surgery*, 18(3), 148-151.
70. Lowey, M. (1993). The development of a new method of cephalometric and study cast mensuration with a computer controlled, video image capture system. Part II: Study cast mensuration. *British Journal of Orthodontics*, 20(4), 315-331.
71. Nagasaka, S., Fujimura, T. ve Segoshi, K. (2003). Development of a non-radiographic cephalometric system. *The European Journal of Orthodontics*, 25(1), 77-85.
72. Nimkarn, Y. ve Miles, P. (1995). Reliability of computer-generated cephalometrics. *The International journal of adult orthodontics and orthognathic surgery*, 10(1), 43-52.
73. Oliver, R. G. (1991). Cephalometric analysis comparing five different methods. *British journal of orthodontics*, 18(4), 277-283.
74. Çelik, E. E. (2007). Konvansiyonel teknik ve bilgisayar ile yapılmış sefalometrik analizlerin güvenilirlik açısından karşılaştırılması.
75. Uysal, T., Baysal, A. ve Yagci, A. (2009). Evaluation of speed, repeatability, and reproducibility of digital radiography with manual versus computer-assisted cephalometric analyses. *The European Journal of Orthodontics*, 31(5), 523-528.

76. Aharon, P., Eisig, S. ve Cisneros, G. (1997). Surgical prediction reliability: a comparison of two computer software systems. *The International journal of adult orthodontics and orthognathic surgery*, 12(1), 65-78.
77. Baskin, H. ve Cisneros, G. J. (1997). A comparison of two computer cephalometric programs. *Journal of clinical orthodontics: JCO*, 31(4), 231-233.
78. Sayinsu, K., Isik, F., Trakyali, G. ve Arun, T. (2007). An evaluation of the errors in cephalometric measurements on scanned cephalometric images and conventional tracings. *The european journal of orthodontics*, 29(1), 105-108.
79. Gregston, M. D., Kula, T., Hardman, P., Glaros, A. ve Kula, K., Year editör^editörler. A comparison of conventional and digital radiographic methods and cephalometric analysis software: I. hard tissue. *Seminars in Orthodontics*; 2004: Elsevier; Published.
80. Farooq, M. U., Khan, M. A., Imran, S., Sameera, A., Qureshi, A., Ahmed, S. A., ve ark. (2016). Assessing the reliability of digitalized cephalometric analysis in comparison with manual cephalometric analysis. *Journal of clinical and diagnostic research: JCDR*, 10(10), ZC20.
81. Erkan, M., Gurel, H. G., Nur, M. ve Demirel, B. (2012). Reliability of four different computerized cephalometric analysis programs. *The European Journal of Orthodontics*, 34(3), 318-321.
82. Paixão, M. B., Sobral, M. C., Vogel, C. J. ve Araujo, T. M. d. (2010). Comparative study between manual and digital cephalometric tracing using Dolphin Imaging software with lateral radiographs. *Dental Press Journal of Orthodontics*, 15, 123-130.
83. Shapiro, S. C. (1992). *Encyclopedia of artificial intelligence* second edition. New Jersey: A Wiley Interscience Publication.
84. Bush, V. (2021). As we may think (1945).
85. Holmes, J., Sacchi, L. ve Bellazzi, R. (2004). Artificial intelligence in medicine. *Ann R Coll Surg Engl*, 86, 334-338.
86. Khanagar, S. B., Al-Ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., ve ark. (2021). Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *Journal of dental sciences*, 16(1), 508-522.
87. **Haugeland, J.** (1989). *Artificial intelligence: The very idea*. MIT press.
88. Schwartz, W. B., Patil, R. S. ve Szolovits, P. 1987. Artificial intelligence in medicine. *Mass Medical Soc*; s. 685-688.
89. Faber, J., Faber, C. ve Faber, P. (2019). Artificial intelligence in orthodontics. *APOS trends orthod*, 9(4), 201-205.
90. Bishop, C. M. (2006). Pattern recognition and machine learning. *Springer google schola*, 2, 1122-1128.
91. Ko, C.-C., Tanikawa, C., Wu, T.-H., Pastewait, M., Jackson, C. B., Kwon, J. J., ve ark. (2019). Machine learning in orthodontics: application review. *Embrac Nov Technol Dent Orthod*, 1001, 117.
92. Zhou, Z.-H. ve Jiang, Y. (2004). NeC4. 5: Neural ensemble based C4. 5. *IEEE Transactions on knowledge and data engineering*, 16(6), 770-773.
93. **Goodfellow, I., Bengio, Y. ve Courville, A.** (2016). *Deep learning*. MIT press.
94. Zadrozny, B., Year editör^editörler. Learning and evaluating classifiers under sample selection bias. *Proceedings of the twenty-first international conference on Machine learning*; 2004 Published.

95. Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78-87.
96. Shorten, C. ve Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48.
97. Samuel, A. L. (1967). Some studies in machine learning using the game of checkers. II—Recent progress. *IBM Journal of research and development*, 11(6), 601-617.
98. Nichols, J. A., Herbert Chan, H. W. ve Baker, M. A. (2019). Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophysical reviews*, 11, 111-118.
99. Steimann, F. (2001). On the use and usefulness of fuzzy sets in medical AI. *Artificial intelligence in medicine*, 21(1-3), 131-137.
100. Öztürk, K. ve Şahin, M. E. (2018). Yapay sinir ağları ve yapay zeka'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
101. Lee, J.-G., Jun, S., Cho, Y.-W., Lee, H., Kim, G. B., Seo, J. B. ve Kim, N. (2017). Deep learning in medical imaging: general overview. *Korean journal of radiology*, 18(4), 570.
102. **BAŞARAN, E.** (2020) *TİMPANİK MEMBRAN GÖRÜNTÜ ANALİZİ VE YAPAY ZEKA KULLANILARAK SANAL OTİTİS MEDİA TANI SİSTEMİNİN GELİŞTİRİLMESİ*
103. Hwang, J.-J., Jung, Y.-H., Cho, B.-H. ve Heo, M.-S. (2019). An overview of deep learning in the field of dentistry. *Imaging science in dentistry*, 49(1), 1.
104. Burt, J. R., Torosdagli, N., Khosravan, N., RaviPrakash, H., Mortazi, A., Tissavirasingham, F., ve ark. (2018). Deep learning beyond cats and dogs: recent advances in diagnosing breast cancer with deep neural networks. *The British journal of radiology*, 91(1089), 20170545.
105. Aminoshariae, A., Kulild, J. ve Nagendrababu, V. (2021). Artificial intelligence in endodontics: current applications and future directions. *Journal of endodontics*, 47(9), 1352-1357.
106. Ağyar, Z. (2015). Yapay sinir ağlarının kullanım alanları ve bir uygulama. *Mühendis ve Makine*, 56(662), 22-23.
107. Leijnen, S. ve van Veen, F. 2020. The neural network zoo. *Proceedings* 47 (1), 9.
108. **Priddy, K. L. ve Keller, P. E.** (2005). *Artificial neural networks: an introduction*. SPIE press.
109. Pham, D. T. ve Karaboga, D. (1999). Training Elman and Jordan networks for system identification using genetic algorithms. *Artificial Intelligence in Engineering*, 13(2), 107-117.
110. Suzuki, K. (2017). Overview of deep learning in medical imaging. *Radiological physics and technology*, 10(3), 257-273.
111. **Murphy, K. P.** (2012). *Machine learning: a probabilistic perspective*. MIT press.
112. Üzen, H. ve Hanbay, K. (2020). Yaya özellik tanıma için LM filtre temelli derin evrimsel sinir ağı. *Politeknik Dergisi*, 23(3), 605-613.
113. Arı, A. ve Hanbay, D. (2019). Tumor detection in MR images of regional convolutional neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(3), 1395-1408.
114. Chen, C.-Y., Lin, Y.-T., Lee, S.-J., Tsai, W.-C., Huang, T.-C., Liu, Y.-H., ve ark. (2022). Automated ECG classification based on 1D deep learning network. *Methods*, 202, 127-135.

115. İnik, Ö. ve Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
116. Kızrak, M. A. ve Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286.
117. Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
118. Shadeed, G. A., Tawfeeq, M. A. ve Mahmoud, S. M., Year editör^editörler. Automatic medical images segmentation based on deep learning networks. IOP Conference Series: Materials Science and Engineering; 2020: IOP Publishing; Published.
119. Simonyan, K. ve Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:14091556*.
120. Gündüz, G. ve Cedimoğlu, İ. H. (2019). Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini. *Sakarya University Journal of Computer and Information Sciences*, 2(1), 9-17.
121. He, K., Zhang, X., Ren, S. ve Sun, J., Year editör^editörler. Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition; 2016 Published.
122. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ve ark., Year editör^editörler. Going deeper with convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition; 2015 Published.
123. Pascanu, R., Mikolov, T. ve Bengio, Y., Year editör^editörler. On the difficulty of training recurrent neural networks. International conference on machine learning; 2013: Pmlr; Published.
124. Hochreiter, S. ve Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
125. **Karakoç, M.** (2011) *Görüntü işleme teknikleri ve yapay zeka yöntemleri kullanarak görüntü içinde görüntü arama*
126. Çubukçu, A., Kuncan, M., İmren, M., Erol, F., Ertunç, H. M., Öztürk, S. ve Kaplan, K. (2015). Görüntü işleme ile 3 eksenli robot mekanizması üzerinde nesne ayırt edilmesi ve sıralanması.
127. **McAndrew, A.** (2004). *An introduction to digital image processing with MATLAB*. Course Technology Press.
128. Eldem, A., Eldem, H. ve Palalı, A. (2017). Görüntü işleme teknikleriyle yüz algılama sistemi geliştirme. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 6(2), 44-48.
129. Onat, M. (2008). Dijital görüntü işleme yöntemleriyle lifli beton numunelerindeki çatlakların tespit edilmesi. *Elazığ: Fırat Üniversitesi Fen Bilimleri Enstitüsü*.
130. Kılıç, B., İbrahim, A. H., Aksoy, S., Sakman, M. C., Demircan, G. S. ve Önal-Süzek, T. (2024). A family-centered orthodontic screening approach using a machine learning-based mobile application. *Journal of Dental Sciences*, 19(1), 186-195.
131. de Dumast, P., Mirabel, C., Cevidanes, L., Ruellas, A., Yatabe, M., Ioshida, M., ve ark. (2018). A web-based system for neural network based classification in temporomandibular joint osteoarthritis. *Computerized Medical Imaging and Graphics*, 67, 45-54.
132. Yamaguchi, S., Lee, C., Karaer, O., Ban, S., Mine, A. ve Imazato, S. (2019). Predicting the debonding of CAD/CAM composite resin crowns with AI. *Journal of Dental Research*, 98(11), 1234-1238.

133. Arijji, Y., Yanashita, Y., Kutsuna, S., Muramatsu, C., Fukuda, M., Kise, Y., ve ark. (2019). Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. *Oral surgery, oral medicine, oral pathology and oral radiology*, 128(4), 424-430.
134. Krois, J., Ekert, T., Meinhold, L., Golla, T., Kharbot, B., Wittemeier, A., ve ark. (2019). Deep learning for the radiographic detection of periodontal bone loss. *Scientific reports*, 9(1), 8495.
135. Kim, D. W., Lee, S., Kwon, S., Nam, W., Cha, I.-H. ve Kim, H. J. (2019). Deep learning-based survival prediction of oral cancer patients. *Scientific reports*, 9(1), 6994.
136. Lee, J.-H., Kim, D.-H., Jeong, S.-N. ve Choi, S.-H. (2018). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of dentistry*, 77, 106-111.
137. Cruz, A. S., Lins, H. C., Medeiros, R. V., Filho, J. M. ve da Silva, S. G. (2018). Artificial intelligence on the identification of risk groups for osteoporosis, a general review. *Biomedical engineering online*, 17, 1-17.
138. Levy-Mandel, A., Venetsanopoulos, A. ve Tsotsos, J. (1986). Knowledge-based landmarking of cephalograms. *Computers and Biomedical Research*, 19(3), 282-309.
139. Jeon, S. ve Lee, K. C. (2021). Comparison of cephalometric measurements between conventional and automatic cephalometric analysis using convolutional neural network. *Progress in Orthodontics*, 22, 1-8.
140. Park, J.-H., Hwang, H.-W., Moon, J.-H., Yu, Y., Kim, H., Her, S.-B., ve ark. (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.
141. Hwang, H.-W., Park, J.-H., Moon, J.-H., Yu, Y., Kim, H., Her, S.-B., ve ark. (2020). Automated identification of cephalometric landmarks: Part 2-Might it be better than human? *The Angle Orthodontist*, 90(1), 69-76.
142. Leonardi, R., Giordano, D., Maiorana, F. ve Spampinato, C. (2008). Automatic cephalometric analysis: a systematic review. *The Angle Orthodontist*, 78(1), 145-151.
143. Miller, R. L., Dijkman, D. J., Riolo, M. L. ve Moyers, R. E. (1971). Graphic computerization of cephalometric data. *Journal of Dental Research*, 50(5), 1363-1363.
144. Savage, A. W., Showfety, K. J. ve Yancey, J. (1987). Repeated measures analysis of geometrically constructed and directly determined cephalometric points. *American Journal of Orthodontics and Dentofacial Orthopedics*, 91(4), 295-299.
145. Hutton, T. J., Cunningham, S. ve Hammond, P. (2000). An evaluation of active shape models for the automatic identification of cephalometric landmarks. *The European Journal of Orthodontics*, 22(5), 499-508.
146. Lindner, C., Wang, C.-W., Huang, C.-T., Li, C.-H., Chang, S.-W. ve Cootes, T. F. (2016). Fully automatic system for accurate localisation and analysis of cephalometric landmarks in lateral cephalograms. *Scientific reports*, 6(1), 33581.
147. Bulatova, G., Kusnoto, B., Grace, V., Tsay, T. P., Avenetti, D. M. ve Sanchez, F. J. C. (2021). Assessment of automatic cephalometric landmark identification using artificial intelligence. *Orthodontics & Craniofacial Research*, 24, 37-42.
148. Proffit, W. R., Fields Jr, H. ve Moray, L. (1998). Prevalence of malocclusion and orthodontic treatment need in the United States: estimates from the NHANES III survey. *The International journal of adult orthodontics and orthognathic surgery*, 13(2), 97-106.

149. Tymofiyeva, O., Proff, P. C., Rottner, K., Düring, M., Jakob, P. M. ve Richter, E.-J. (2013). Diagnosis of dental abnormalities in children using 3-dimensional magnetic resonance imaging. *Journal of Oral and Maxillofacial Surgery*, 71(7), 1159-1169.
150. Tymofiyeva, O., Rottner, K., Jakob, P., Richter, E.-J. ve Proff, P. (2010). Three-dimensional localization of impacted teeth using magnetic resonance imaging. *Clinical oral investigations*, 14, 169-176.
151. White, S. C. (2008). Cone-beam imaging in dentistry. *Health physics*, 95(5), 628-637.
152. Halazonetis, D. J. (2005). From 2-dimensional cephalograms to 3-dimensional computed tomography scans. *American journal of orthodontics and dentofacial orthopedics*, 127(5), 627-637.
153. **Swennen, G. R., Schutyser, F. A. ve Hausamen, J.-E.** (2005). *Three-dimensional cephalometry: a color atlas and manual*. Springer Science & Business Media.
154. Yamamoto, K., Ueno, K., Seo, K. ve Shinohara, D. (2003). Development of dento-maxillofacial cone beam X-ray computed tomography system. *Orthodontics & craniofacial research*, 6.
155. Koo, T. K. ve Li, M. Y. (2016). A guideline of selecting and reporting intraclass correlation coefficients for reliability research. *Journal of chiropractic medicine*, 15(2), 155-163.
156. Obermeyer, Z. ve Emanuel, E. J. (2016). Predicting the future—big data, machine learning, and clinical medicine. *The New England journal of medicine*, 375(13), 1216.
157. Yassir, Y. A., Salman, A. R. ve Nabbat, S. A. (2022). The accuracy and reliability of WebCeph for cephalometric analysis. *Journal of Taibah University Medical Sciences*, 17(1), 57-66.
158. Anuwongnukroh, N., Dechkunakorn, S., Damrongsri, S., Nilwarat, C., Pudpong, N., Radomsutthisarn, W. ve Kangern, S. (2018). Assessment of the reliability of automatic cephalometric analysis software. *International Journal of Mechanical Engineering and Robotics Research*, 7(1), 61-65.
159. Periago, D. R., Scarfe, W. C., Moshiri, M., Scheetz, J. P., Silveira, A. M. ve Farman, A. G. (2008). Linear accuracy and reliability of cone beam CT derived 3-dimensional images constructed using an orthodontic volumetric rendering program. *The Angle Orthodontist*, 78(3), 387-395.
160. Olszewski, R., Reyhler, H., Cosnard, G., Denis, J., Vynckier, S. ve Zech, F. (2008). Accuracy of three-dimensional (3D) craniofacial cephalometric landmarks on a low-dose 3D computed tomograph. *Dentomaxillofacial Radiology*, 37(5), 261-267.
161. Cavalcanti, M. G. P., Rocha, S. ve Vannier, M. (2004). Craniofacial measurements based on 3D-CT volume rendering: implications for clinical applications. *Dentomaxillofacial Radiology*, 33(3), 170-176.
162. Zamora, N., Llamas, J. M., Cibrián, R., Gandia, J. L. ve Paredes, V. (2011). Cephalometric measurements from 3D reconstructed images compared with conventional 2D images. *The Angle Orthodontist*, 81(5), 856-864.
163. Yitschaky, O., Redlich, M., Abed, Y., Faerman, M., Casap, N. ve Hiller, N. (2011). Comparison of common hard tissue cephalometric measurements between computed tomography 3D reconstruction and conventional 2D cephalometric images. *The Angle Orthodontist*, 81(1), 11-16.
164. Kılınç, D. D., Kircelli, B. H., Sadry, S. ve Karaman, A. (2022). Evaluation and comparison of smartphone application tracing, web based artificial intelligence tracing

- and conventional hand tracing methods. *Journal of Stomatology, Oral and Maxillofacial Surgery*, 123(6), e906-e915.
165. Guinot-Barona, C., Alonso Pérez-Barquero, J., Galán López, L., Barmak, A. B., Att, W., Koïs, J. C. ve Revilla-León, M. (2024). Cephalometric analysis performance discrepancy between orthodontists and an artificial intelligence model using lateral cephalometric radiographs. *Journal of Esthetic and Restorative Dentistry*, 36(4), 555-565.
 166. Kumar, M., Kumari, S., Chandna, A., Singh, A. ve Kumar, H. (2020). Comparative evaluation of CephNinja for android and NemoCeph for computer for cephalometric analysis: A study to evaluate the diagnostic performance of CephNinja for cephalometric analysis. *Journal of International Society of Preventive and Community Dentistry*, 10(3), 286-291.
 167. Kumar, M., Kumari, S., Shetty, P., Kumar, R. R., Singh, D. P. ve Shetty, P. (2019). Comparative evaluation of NemoCeph and Foxit PDF reader for Steiner's cephalometric analysis. *J Contemp Dent Pract*, 20, 1051-1055.
 168. Alcalde, L. F. A., Faria, P. E. P., Nogueira, R. L. M., Chihara, L. ve Sant'Ana, E. (2019). Computed tomography visualizing alterations in the upper airway after orthognathic surgery. *Journal of Cranio-Maxillofacial Surgery*, 47(7), 1041-1045.
 169. Ramírez-Sotelo, L. R., Almeida, S., Ambrosano, G. M. ve Bóscolo, F. (2012). Validity and reproducibility of cephalometric measurements performed in full and hemifacial reconstructions derived from cone beam computed tomography. *The Angle Orthodontist*, 82(5), 827-832.
 170. Ristau, B., Coreil, M., Chapple, A., Armbruster, P. ve Ballard, R. (2022). Comparison of AudaxCeph®'s fully automated cephalometric tracing technology to a semi-automated approach by human examiners. *International orthodontics*, 20(4), 100691.
 171. Kunz, F., Stellzig-Eisenhauer, A., Widmaier, L. M., Zeman, F. ve Boldt, J. (2023). Assessment of the quality of different commercial providers using artificial intelligence for automated cephalometric analysis compared to human orthodontic experts. *Journal of Orofacial Orthopedics/Fortschritte der Kieferorthopädie*, 1-16.
 172. Çoban, G., Öztürk, T., Hashimli, N. ve Yağci, A. (2022). Comparison between cephalometric measurements using digital manual and web-based artificial intelligence cephalometric tracing software. *Dental Press Journal of Orthodontics*, 27, e222112.
 173. Silva, T. P., Hughes, M. M., Menezes, L. d. S., de Melo, M. d. F. B., Freitas, P. H. L. d. ve Takeshita, W. M. (2022). Artificial intelligence-based cephalometric landmark annotation and measurements according to Arnett's analysis: can we trust a bot to do that? *Dentomaxillofacial Radiology*, 51(6), 20200548.
 174. Meriç, P. ve Naoumova, J. (2020). Web-based fully automated cephalometric analysis: comparisons between app-aided, computerized, and manual tracings. *Turkish journal of orthodontics*, 33(3), 142.
 175. Mosleh, M. A. A., Baba, M. S., Malek, S. ve Almaktari, R. A. (2016). Ceph-X: development and evaluation of 2D cephalometric system. *BMC bioinformatics*, 17(19), 193-201.
 176. Bholsithi, W., Tharanon, W., Chintakanon, K., Komolpis, R. ve Sinthanayothin, C. (2009). 3D vs. 2D cephalometric analysis comparisons with repeated measurements from 20 Thai males and 20 Thai females. *Biomedical imaging and intervention journal*, 5(4), e21.
 177. Grubb, J. E., Smith, T. ve Sinclair, P. (1996). Clinical and scientific applications/advances in video imaging. *The Angle Orthodontist*, 66(6), 407-416.

178. Gürdal, P., Hildebolt, C. ve Akdeniz, B. (2001). The effects of different image file formats and image-analysis software programs on dental radiometric digital evaluations. *Dentomaxillofacial Radiology*, 30(1), 50-55.
179. Perrotti, G., Goker, F., Rossi, O., Nowakowska, J., Russillo, A., Beltramini, G., ve ark. (2023). 3D Computed Tomography vs. 2D radiography: comparison of 3D direct anthropometry with 2D norm calculations and analysis of differences in soft tissue measurements. *European Review for Medical and Pharmacological Sciences*, 27(3 Suppl.), 46-60.
180. Duran, G. S., Gökmen, Ş., Topsakal, K. G. ve Görgülü, S. (2023). Evaluation of the accuracy of fully automatic cephalometric analysis software with artificial intelligence algorithm. *Orthodontics & Craniofacial Research*, 26(3), 481-490.
181. Zamrik, O. M. ve İşeri, H. (2021). The reliability and reproducibility of an Android cephalometric smartphone application in comparison with the conventional method. *The Angle Orthodontist*, 91(2), 236-242.
182. Mohan, A., Sivakumar, A. ve Nalabothu, P. (2021). Evaluation of accuracy and reliability of OneCeph digital cephalometric analysis in comparison with manual cephalometric analysis—a cross-sectional study. *BDJ open*, 7(1), 22.
183. Favaedi, L. ve Petrou, M., Year editör^editörler. Cephalometric landmarks identification using probabilistic relaxation. 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology; 2010: IEEE; Published.



