



**DERİN ÖĞRENME YÖNTEMİNİN
YÜZÜN FOTOĞRAFİK İNCELENMESİNDEKİ
ETKİNLİĞİNİN DEĞERLENDİRİLMESİ**

Mehmet Rıdvan DEMİR

Ortodonti Ana Bilim Dalı

**Tez Danışmanı
Doç. Dr. Ali KİKİ**

Doktora Tezi-2023



SAĞLIK BİLİMLERİ ENSTİTÜSÜ
Graduate School of Health Sciences

**DERİN ÖĞRENME YÖNTEMİNİN
YÜZÜN FOTOĞRAFİK İNCELENMESİNDEKİ
ETKİNLİĞİNİN DEĞERLENDİRİLMESİ**

Mehmet Rıdvan DEMİR

**Ortodonti Ana Bilim Dalı
Doktora Tezi**

**Tez Danışmanı
Doç. Dr. Ali KİKİ**

**ERZURUM
2023**

İÇİNDEKİLER

İÇİNDEKİLER	I
TEŞEKKÜR	IV
ÖZET	V
ABSTRACT.....	VI
SİMGELER VE KISALTMALAR DİZİNİ	VII
ŞEKİLLER DİZİNİ.....	VIII
TABLolar DİZİNİ	X
1. GİRİŞ	1
2. GENEL BİLGİLER.....	4
2.1. Yüz İncelemeleri.....	4
2.1.1. Doğrudan Yüz İncelemeleri	5
2.1.1.1. Kraniyometri.....	5
2.1.1.2. Antropometri	6
2.1.2. Dolaylı Yüz İncelemeleri	6
2.1.2.1. Sefalometrik İnceleme	7
2.1.2.2. Fotoğrafik İnceleme.....	7
2.1.2.3. Üç Boyutlu Görüntülemelerle İnceleme	13
2.2. Yapay Zeka.....	17
2.2.1. Yapay Zeka ve Tarihçesi	17
2.2.2. Yapay Zeka Tanımı ve Alt Alanları	18
2.2.3. Yapay Sinir Ağları.....	21
2.2.4. Derin Öğrenme	22
2.2.4.1. Derin Öğrenme Mimarileri	24
2.2.4.2. Derin Öğrenme Kütüphaneleri	26

2.2.5. Diş Hekimliğinde Yapay Zeka	27
2.2.6. Ortodontide Yapay Zeka Uygulamaları	30
3. MATERYAL VE METOT	34
3.1. Fotoğrafların Etiketlenmesi	35
3.2. Model Eğitimi için Ön Hazırlık Aşaması	38
3.3. Derin Öğrenme Modeli Eğitim Aşaması	39
3.4. Model Performansının Ölçüm Aşaması.....	42
3.5. Derin Öğrenme Modelinin Performansının Değerlendirilmesi	44
3.5.1. Değerlendirme Metrikleri.....	44
3.5.1.1. Standart Sapma ile Birlikte Ortalama Radyal Hata	44
3.5.1.2. Başarı Tespit Oranı	45
3.6. İstatistiksel Değerlendirme	45
3.6.1. Ortalama Radyal Hataların Değerlendirilmesi	46
3.6.2. Başarı Tespit Oranlarının Değerlendirilmesi	46
4. BULGULAR	47
4.1. Ortalama Radyal Hata ve Standart Sapma Değerlerine Ait Bulgular.....	47
4.1.1. Derin Öğrenme Modeli Tahminlerine Ait Bulgular.....	47
4.1.1.1. Ortalama Radyal Hata	47
4.1.1.2. Başarı Tespit Oranı	49
4.1.2. Araştırmacının İkinci Kez Etiketlemesine Ait Bulgular	52
4.1.2.1. Ortalama Radyal Hata	52
4.1.2.2. Başarı Tespit Oranı	52
4.1.3. İkinci Araştırmacı Etiketlemesine İlişkin Bulgular.....	54
4.1.3.1. Ortalama Radyal Hata	54
4.1.3.2. Başarı Tespit Oranı	54

4.2. Arařtırmacıların ve Derin Öğrenme Modeli Tahminlerinin Ortalama Radyal Hata ve Standart Sapma Deęerlerinin Karşılaştırılması.....	57
4.3. Arařtırmacıların ve Derin Öğrenme Modelinin Başarı Tespit Oranlarının Karşılaştırılması	59
5. TARTIřMA	61
6. SONUÇ VE ÖNERİLER.....	74
KAYNAKLAR	76
EKLER	94
EK-1. ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	94
EK-2. ETİK KURUL ONAY FORMU	95
EK-3. DİĞER FORMLAR.....	97

TEŞEKKÜR

Doktora tezi olarak hazırlayıp sunduğum bu çalışmanın tüm aşamalarını özenle yürüten, klinik deneyimlerinden çokça yararlandığım, ilgisini ve desteğini esirgemeyen değerli danışman hocam Sayın Doç. Dr. Ali KİKİ'ye;

Tezime gösterdikleri ilgi ve destekten dolayı kıymetli hocalarım Sayın Prof. Dr. Nihat KILIÇ (Atatürk Üniversitesi, Erzurum) ve Sayın Doç. Dr. Fatih Şengül'e (Atatürk Üniversitesi, Erzurum); hem lisans hem de lisansüstü eğitimimdeki katkılarından dolayı kıymetli hocalarım Sayın Prof. Dr. Abdulvahit ERDEM'e (Atatürk Üniversitesi, Erzurum), Sayın Prof. Dr. İsmail CEYLAN'a (Atatürk Üniversitesi, Erzurum) ve Sayın Dr. Öğr. Üyesi Nurhan BAYINDIR DURNA'ya (Atatürk Üniversitesi, Erzurum); tez çalışmamda yapay zeka alanındaki desteklerinden dolayı kıymetli hocalarım Sayın Doç. Dr. İbrahim Şevki BAYRAKDAR'a (Eskişehir Osmangazi Üniversitesi, Eskişehir), Sayın Doç. Dr. Mehmet UĞURLU'ya (Eskişehir Osmangazi Üniversitesi, Eskişehir) ve Sayın Müh. Dr. Özer ÇELİK'e (Eskişehir Osmangazi Üniversitesi, Eskişehir); doktora eğitimim boyunca klinikte birlikte çalışmaktan keyif aldığım asistan arkadaşlarıma ve kıymetli aileme teşekkürlerimi borç bilirim.

Mehmet Rıdvan DEMİR

ÖZET

Derin Öğrenme Yönteminin Yüzün Fotoğrafik İncelenmesindeki Etkinliğinin Değerlendirilmesi

Amaç: Ortodontik yüz fotoğraflarının kantitatif analizleri, anatomik referans noktalarının tespit edilmesiyle başlar. Bu tez çalışmasının amacı derin öğrenme yöntemiyle yüz fotoğraflarındaki anatomik referans noktalarının tespit edilmesi ve geliştirilen derin öğrenme modelinin performansının değerlendirilmesidir.

Materyal ve Metot: Bu çalışmada, derin öğrenme modelinin geliştirilmesi için 2872 yüz fotoğrafı ve 39 anatomik referans noktası kullanılmıştır. Model eğitimi için iki derin öğrenme mimarisi kullanılmıştır: PIPNet ve omurga ağı olarak kullanılan ResNet101. Model eğitimi, 2100 görüntüden oluşan bir eğitim veri kümesi ve 772 görüntüden oluşan bir test veri kümesi oluşturularak gerçekleştirilmiştir. Ortalama radyal hata ve başarı tespit oranı ölçütleri kullanılarak derin öğrenme modelinin performansı değerlendirilmiştir.

Bulgular: Geliştirilen derin öğrenme modelinin ortalama radyal hata değeri 1.82 ± 2.56 mm olarak hesaplanmıştır. Model tahminleri 1.0 mm, 1.5 mm, 2.0 mm, 2.5 mm, 2.5 mm, 3.0 mm ve 4.0 mm hassasiyet aralıklarında sırasıyla %43.93, %61.96, %73.17, %80.89, %85.83 ve %91.98 başarı tespit oranlarına ulaşmıştır. Çalışma kapsamındaki 39 anatomik referans noktası içinden sağ pupil noktasının en düşük hata değerine ve en yüksek başarı tespit oranına sahip olduğu tespit edilmiştir.

Sonuç: Geliştirilen derin öğrenme modeli, anatomik referans noktalarını tahmin etmede kabul edilebilir başarı tespit oranı göstermiştir: 2.0 mm hassasiyet aralığında %73.17 başarı tespit oranı. Daha iyi model performansı için geniş veri setlerinin kullanılması ve farklı yapay zeka mimarilerinin entegrasyonu faydalı olabilir.

Anahtar Kelimeler: Anatomik işaretler, dental fotoğrafı, derin öğrenme, yapay zeka

ABSTRACT

Determination of the Effectiveness of Deep Learning Method in Facial Photographic Evaluation

Aim: Quantitative analysis of orthodontic facial photographs begins with the identification of anatomical landmarks. The aim of this study is to detect landmarks on the face with deep learning and to evaluate the performance of the developed deep learning model.

Material and method: In this study, 2872 facial photographs and 39 anatomical landmarks were used to develop the deep learning model. Two deep learning architectures were used for model training: PIPNet architecture and ResNet101 architecture used as a backbone network. Model training was performed by creating a training dataset of 2100 images and a test dataset of 772 images. The performance of the resulting deep learning model was evaluated using average radial error and successful detection rate metrics.

Results: The average radial error of the developed deep learning model was calculated as 1.82 ± 2.56 mm. The model predictions achieved 43.93%, 61.96%, 73.17%, 80.89%, 85.83% and 91.98% successful detection rates in the precision ranges of 1.0 mm, 1.5 mm, 2.0 mm, 2.5 mm, 2.5 mm, 3.0 mm, and 4.0 mm, respectively. Among the 39 anatomical landmarks in the study, it was determined that the right pupil point had the lowest error value and highest successful detection rate.

Conclusion: The developed deep learning model was found an acceptable success rate in predicting anatomical landmarks: 73.17% succesful detection rate in 2.0 mm sensitivity range. For better model performance, the use of large datasets and the integration of different artificial intelligence architectures can be beneficial.

Key Words: Anatomic landmarks, artificial intelligence, deep learning, dental photography

SİMGELER VE KISALTMALAR DİZİNİ

BTO	:	Başarı Tespit Oranı (Successful Detection Rate)
DÖ	:	Derin Öğrenme
ESA	:	Evrişimli Sinir Ağları (Convolutional Neural Network)
IBM	:	International Business Machines Corporation
IBÖGTY	:	ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (The ImageNet Large Scale Visual Recognition Challenge)
MIT	:	Massachusetts Institute of Technology
ORH	:	Ortalama Radyal Hata (Mean Radial Error)
R	:	Radyal Hata (Radial Error)
SS	:	Standart Sapma (Standard Deviation)
YSA	:	Yapay Sinir Ağları (Artificial Neural Network)
YOLO, YOLOv3	:	You Only Look Once, You Only Look Once version 3
YZ	:	Yapay Zeka

ŞEKİLLER DİZİNİ

<u>Şekil No</u>	<u>Sayfa No</u>
Şekil 2.1. Ortodontideki rutin fotoğraf kayıtları.....	8
Şekil 2.2. Beşler kuralı.	11
Şekil 2.3. Üçler kuralı.....	12
Şekil 2.4. Yüz orta hattı referans noktaları.	13
Şekil 2.5. Turing testi.	19
Şekil 2.6. Yapay zeka alt alanları	20
Şekil 2.7. Yapay sinir ağı yapısı.	22
Şekil 2.8. Yapay zeka alt kümeleri.....	23
Şekil 2.9. Görüntü tanımanın temel adımları.	24
Şekil 3.1. Yöntem aşamaları.....	35
Şekil 3.2. Veri etiketleme modülünün görünümü.....	36
Şekil 3.3. Veri kümesi dağılımı.	36
Şekil 3.4. Etiketlenen anatomik referans noktaları.....	38
Şekil 3.5. Sırasıyla veri çoğaltma prosedürleri.....	40
Şekil 3.6. Model eğitimimizdeki hiperparametre değerleri.....	41
Şekil 3.7. Model tarafından tahmin edilen (mavi) ve araştırmacı tarafından işaretlenen noktalar (kırmızı).	42
Şekil 3.8. İki koordinat arası mesafe formülü.	43
Şekil 3.9. Dış ve iç kornea noktaları.....	43
Şekil 3.10. Radyal hata formülü.	44
Şekil 3.11. Ortalama radyal hata formülü.....	44
Şekil 3.12. Standart sapma formülü.....	44
Şekil 3.13. Başarı tespit oranı.	45

Şekil 4.1. Derin öğrenme modeline ilişkin ortalama radyal hata değerleri (mm).	48
Şekil 4.2. Derin öğrenme modeli tahminlerine ilişkin 2.0 mm hassasiyet aralığındaki başarı tespit oranları (%).	50



TABLÖLAR DİZİNİ

<u>Tablo No</u>	<u>Sayfa No</u>
Tablo 2.1. Yumaşak doku ve angle felsefesinin karşılaştırılması.	4
Tablo 2.2. Yapay zeka tanımlarının savunucuları.	19
Tablo 2.3. Derin öğrenme algoritmaları.	25
Tablo 3.1. Fotoğraf ekipmanları.	34
Tablo 3.2. Anatomik referans noktaları.	37
Tablo 3.3. Veri hazırlık aşamasında kullanılan kütüphaneler.	39
Tablo 3.4. Model eğitiminde uygulanan veri çoğaltma prosedürleri.	40
Tablo 3.5. Eğitim aşamasında kullanılan kütüphaneler.	41
Tablo 3.6. Ölçüm aşamasında kullanılan kütüphaneler.	43
Tablo 4.1. Derin öğrenme modelinin genel ORH, SS ve BTO değerleri.	47
Tablo 4.2. Derin öğrenme modeli tahminlerine ait ORH, SS ve BTO değerleri.	51
Tablo 4.3. Araştırmacıya ait genel ORH, SS ve BTO değerleri.	52
Tablo 4.4. Araştırmacının yeniden etiketlemesine ait ORH, SS ve BTO değerleri.	53
Tablo 4.5. İkinci araştırmacı etiketlemesine ait genel ORH, SS ve BTO değerleri.	54
Tablo 4.6. İkinci araştırmacı etiketlemesine ait ORH, SS Ve BTO değerleri.	56
Tablo 4.7. Tek yönlü varyans analizi.	57
Tablo 4.8. Korelasyon değerleri.	60

1. GİRİŞ

Günlük yaşantımızda sıklıkla karşılaşmaya başladığımız bir kavram olan yapay zeka (YZ), bilgisayarlara zeki canlılar gibi işlem yapma becerilerini kazandırma yöntemidir. Hızla yükselen YZ kullanılmasının temelinde ise bu becerileri kazanmasını sağlayan daha büyük veri kümeleri ve daha gelişmiş algoritmaların kullanılması yer almaktadır. Güçlü bilgisayarların üretilmesi, büyük veri kümelerine erişmenin kolaylaşması ve problem çözme yöntemlerinin gelişmesi YZ'nın sağlık alanında da yaygın olarak kullanılmasına yol açmıştır. YZ uygulamaları, sağlık alanında hastalıkların teşhisinde, tedavi planlamasında ve hastalık prognozunun belirlenmesinde yaygın bir şekilde kullanılmaktadır. Bu çalışmaların veri kümeleri genellikle tıbbi görüntülerden oluşmaktadır. Sağlık alanındaki dijitalleşme ile tıbbi görüntü verileri artmış ve bu verilere erişimin kolaylaştığı görülmüştür. Görüntü işleme, tıbbi görüntülerin veri kümesi olarak kullanıldığı bir YZ alt alanıdır. Bir derin öğrenme (DÖ) yöntemi olan görüntü işleme, bu gelişmelere paralel olarak popüler hale gelmektedir.

Ortodontide temel teşhis kriterlerinden biri olan yüz fotoğrafları, teşhis, tedavi planı ve uygun tedavi yönteminin belirlenmesi ile tedavi sürecinin ve tedavi sonuçlarının değerlendirilmesi gibi birçok amaç için kullanılmaktadır. Fotoğraflar aracılığıyla; yüzdeki asimetri varlığı, dengeli çene ve yüz gelişimi, profil uyumu ve gülümseme estetiği gibi faktörler değerlendirilir. Yüz fotoğraflarının arşivlenmesi, ortaya çıkabilecek hukuki sorunlar karşısında somut kanıt niteliği taşımaktadır.

Baş ve yüz bölgesinin ilk incelenmesi kraniyometrik yöntemle başlamıştır. Bu yöntemde ölçümler doğrudan kafatasları üzerinden yapılmıştır. Daha sonra antropometrik yöntemle cetvel ve kumpas kullanılarak yüz üzerinde doğrudan lineer ve açısal ölçümler gerçekleştirilmiştir. Günümüzde bu eski yöntemlerin yerini gelişmiş görüntüleme teknikleri ve dolaylı ölçüm olanağı sunan yazılımlar almıştır. Yüzün sert dokularının

görüntülenmesi ve incelenmesi standart bir yöntemle ulaşmış olsa da, yüzün yumuşak dokuları için böyle bir standart yöntem tam olarak oluşturulmamıştır. Ortodontide, yüzün sert dokuları sefalometrik radyografiler ve tomografiler ile değerlendirilirken, yüzün yumuşak dokuları genellikle fotoğraflar ile değerlendirilmektedir. Fotoğraf elde etmenin kolaylığı ve ekonomikliğı, üç boyutlu yüz taramalarının yaygın kullanımını sınırlamaktadır. Bununla birlikte fotoğraflar aracılığıyla yüzün değerlendirilmesi çoğunlukla nitelikseldir ve deneyime dayanır. Yüzün niceliksel değerlendirmesi için anatomik referans noktaları kullanılır. Bu noktaların neredeyse tamamı Farkas ve Deutsch tarafından yüz incelemelerinde kullanılması için tanımlanmıştır (Farkas ve Deutsch, 1996). Yüz üzerinde Farkas ve Deutsch tarafından tanımlanan bu referans noktalarının tam olarak belirlenmesi oldukça zordur. Bu noktaların tayini kişiden kişiye değişmekle kalmaz, farklı bir zamanda aynı kişinin aynı noktayı birebir işaretlemesi de pek olası değildir. Bu nedenle Rakosi (Rakosi, 1982) 2 mm'lik bir hatanın, Forsyth ve Davis (Forsyth ve Davis, 1996) ise 1 mm'lik bir hatanın lateral sefalometrik filmler için kabul edilebilir olduğunu belirtmiştir.

Noktaların doğru ve tekrarlanabilir bir yöntemle tespit edilmesinin, yüzün niceliksel olarak değerlendirilmesinde ilk adım olduğu söylenebilir. Yüz fotoğrafları üzerinde referans noktaları doğru ve tekrarlanabilir bir şekilde belirlenirse yüzde lineer, açısal ve oransal ölçümler elde edilebilir.

Güncel bir konu olan ortodontideki DÖ uygulamalarının çoğu, sefalometrik röntgenlerde anatomik referans noktalarının otomatik olarak tespit edilmesi ile ilgilidir (Schwendicke ve ark., 2021). Bu çalışmaların veri kümeleri sefalometrik radyografilerden oluşmaktadır. Model eğitimi ve anatomik referans noktalarının tespitleri de bu siyah-beyaz radyografiler üzerinden gerçekleştirilmektedir. Çalışmamızın veri

kümesini ise cephe istirahat yüz fotoğrafları oluşturmaktadır ve anatomik referans noktaları yüzde konumlanmış yumuşak doku noktalarıdır.

Literatürde sonucunda bu çalışma konusu ile benzer iki çalışmaya rastlanmıştır. Rousseau ve Retrouvey (2022) çalışmalarında 45 hastada yüzün dikey boyutlarını otomatik olarak analiz etmeyi amaçlamış ve dört anatomik referans noktası kullanmışlardır: nasion, subnasale, gnation ve interlabial temas noktası (Rousseau ve Retrouvey, 2022). Bu çalışma ile benzer olarak, bu referans noktalarından ilk üçü bizim çalışmamızda da kullanılmıştır. Benzer diğer çalışmada ise Rao ve ark. (2019) 22 adet gönüllünün yüz fotoğrafında 19 nokta kullanarak 10 ölçüm hesaplamıştır (Rao ve ark., 2019).

Çalışmamızda, referans noktalarının tam olarak tespit edilmesindeki belirsizliği aşabilmek için DÖ yöntemi kullanılmış ve yüz incelemesi için 39 anatomik referans noktası belirlenmiştir. Ayrıca, model eğitimi için diğer iki çalışmaya kıyasla çok daha fazla sayıda yüz görüntüsü (eğitim setinde 2100 ve test setinde 772 olmak üzere toplam 2872 yüz görüntüsü) kullanılmıştır. Bunların yanında, çalışmamızda kornea çapını hesaplamak için tanımlanmış iki referans noktası bulunmakta olup böylece noktaların ortalama hata değerleri cetvel gereksinimi olmadan milimetre türünden hesaplanmıştır.

Bu çalışmanın ana hipotezi, DÖ yöntemleriyle yüz fotoğrafları üzerinde anatomik referans noktalarının tespit edilmesinin mümkün olduğudur. Bu çalışmanın amacı ise, DÖ yönteminin yüz fotoğrafları üzerinde anatomik referans noktalarını doğru bir şekilde tespit etmesindeki etkinliğini değerlendirmektir.

2. GENEL BİLGİLER

2.1. Yüz İncelemeleri

Ortodontik tedavinin yüz üzerindeki etkilerine, 19. yüzyılın önde gelen ortodontistlerinden Norman Kingsley tarafından dikkat çekilse de 21. yüzyılın başlarına kadar yüz estetiği oklüzyonun gölgesinde kalmıştır. Bu süreçte Angle'ın görüşleri uzun bir süre hâkim olmuştur. Edward Angle, optimum yüz estetiğinin her zaman ideal oklüzyonla örtüştüğünü ve estetiğin oklüzyon lehine göz ardı edilebileceğini belirtmiştir. Yirminci yüzyılın büyük çoğunluğunda, ortodontik tedavinin asıl hedefinin oklüzyon olduğu ve estetiğin ikincil bir hedef olduğu fikri devam etmiştir. Yirminci yüzyılın ikinci yarısında ortognatik cerrahi girişimler ve çocuklarda büyüme modifikasyonu önem kazanmıştır. Bu dönemde de tedaviler daha iyi oklüzyon elde etmek için yapılmaya devam etmiştir. Estetik diş hekimliğinin yaygınlaştığı yirminci yüzyılın sonlarında tedavinin öncelikli hedefi ideal oklüzyon olarak kalsa da, hasta memnuniyeti için estetiğin çok önemli olduğu kabul görmüştür (Sarver ve Ackerman, 2000). Güncel olarak kabul gören yumuşak doku felsefesinde modern ortodontik ve ortognatik tedavinin hedef ve sınırlarının diş ve iskeletsel yapı tarafından değil, yüzün yumuşak dokuları tarafından tayin edildiği belirtilmektedir (Proffit ve ark., 2018, s.4-5). Yumuşak doku felsefesi ve ortodontide kökleşmiş olan Angle felsefesinin karşılaştırılması aşağıda gösterilmiştir.

Tablo 2.1. Yumuşak doku ve angle felsefesinin karşılaştırılması.

	Angle Felsefesi	Yumuşak Doku Felsefesi
Primer tedavi hedefi	: İdeal dental oklüzyondur.	İdeal yumuşak doku oranlarıdır.
Sekonder hedef	: İdeal çene ilişkisidir.	Fonksiyonel oklüzyondur.
Sert-yumuşak doku ilişkisi	: İdeal olan sert doku ideal olan yumuşak dokuyu üretir	İdeal olan yumuşak doku ideal olan sert dokuyu üretir
Teşhis materyalleri	: Alçı modeller ve sefalometrik radyografilerdir.	Yüz yumuşak dokularının ve intraoral yapıların klinik muayenesidir.
Tedavi yaklaşımı	: İdeal dental ve iskeletsel ilişki sonucunda ideal yumuşak doku ortaya çıkar.	İdeal yumuşak doku ilişkisi sağlandıktan sonra dişlerin ve çenelerin yerleşimi gerçekleşir.
Fonksiyonel yaklaşım	: Oklüzyon hedefine uygun temporomandibular eklem hedefidir.	Dişlerin ideal görünümü hedefine uygun yumuşak doku hareketidir.
Stabilite sonuçları	: Oklüzyonla ilişkilidir.	Yumuşak doku dengesiyle ilişkilidir.

Güncel ortodontik tedavi planlanması yaklaşımlarında yumuşak dokuların değerlendirilmesi önem kazanmıştır. Sert dokular, ortodontik tedavi planlamasındaki hakimiyetini bir miktar kaybetmiş olsa da ideal tedavi hedefleri için sert ve yumuşak dokuların birlikte değerlendirilmesi daha doğru bir yaklaşım olarak karşımıza çıkmaktadır. İnsan kafataslarının doğrudan ölçüldüğü ve birbirleriyle karşılaştırıldığı kraniyometri ile başlayan sert doku incelemeleri, günümüzde yerini büyük oranda üç boyutlu tomografi incelemelerine bırakmıştır. Yumuşak doku incelemelerinde ise, doğrudan bir yöntem olan antropometrik ölçümlerin kullanımı oldukça azalmış olup bu yöntemin yerini sefalometri, fotogrametri, üç boyutlu görüntüleme ve video görüntüleme gibi dolaylı yöntemler almıştır.

2.1.1. Doğrudan Yüz İncelemeleri

Yüzün doğrudan incelenmesini sağlayan iki yöntem vardır. Bunlardan biri antropometri adı verilen ve yaşayan bireyler üzerinde gerçekleştirilen yöntemdir. Diğer yöntem ise kraniyometri adı verilen ve kafatası üzerinde yapılan iskelet ölçüm yöntemidir.

2.1.1.1. Kraniyometri

Kraniyometri, 1813 tarihli Edinburgh Ansiklopedisi'nde hayvanların kafataslarını ölçerek kişiye özgü farklılıkları keşfetme sanatı olarak tanımlanmaktadır. Kraniyometri, 18. ve 19. yüzyıllarda Avrupa mağaralarında bulunan kafataslarını incelemek için kullanılmıştır. Bu iskeletlerden, soyu tükenmiş popülasyonlar hakkında bilgi toplanmış ve kafatasları birbirleriyle karşılaştırılarak yeni bilgiler elde edilmiştir. Kraniyometrinin en yaygın kullanılan ölçümlerinden biri, Camper tarafından tanımlanan, zeka ile ilişkili olduğu düşünülen ve etnik kökeni belirlemek için kullanılan yüz açısıdır (Finlay, 1980). Kraniyometri ile kafatasları üzerinde yapılan ölçümler oldukça hassastır. Diğer yandan,

kraniyometri ölçümleri belirli bir zaman dilimini temsil eder ve büyüme sonucu meydana gelen değişiklikleri değerlendirmek için longitudinal veri elde etmek mümkün değildir (Proffit ve ark., 2018, s.24).

2.1.1.2. Antropometri

Antropometri, Latince insan anlamına gelen “antros” ve ölçü anlamına gelen “metris” kelimelerinin birleşiminden oluşan bir terimdir. Genel anlamda insan bedeninin nesnel özelliklerini, belirli ölçüm yöntemleriyle sınıflandıran bir tekniktir (Kamil, 1991). Tıbbi antropometrinin babası olarak kabul edilen Hrdlička, kumpas ve cetvel gibi aletler kullanarak ölçümler yapmıştır (Hrdlička, 1920). Yirminci yüzyılın ortalarına doğru Hellman, ortodontide antropometrik ölçümlerin kullanımı için standart ve kapsamlı bir yöntem sunmuştur. Bu yöntemle hem büyüme sürecinde hem de tedavi sonucunda yüz yapılarında meydana gelen değişiklikleri ölçmeyi ve yüz estetiğini değerlendirmeyi amaçlamıştır (Hellman, 1939). Farkas ve ark. (2005) çeşitli etnik kökenlere sahip bireylerin yüz ölçümlerini alarak antropometrik standartlar geliştirmiştir. Farkas'ın antropometrik çalışmaları, insan yüz oranları ve bunların zaman içindeki değişimleri hakkında değerli bilgiler sağlamıştır (Farkas ve ark., 2005). Antropometrik ölçümler farklı zamanlarda yapılırsa longitudinal veriler de elde edilebilir. Bu sayede antropometri, bir bireyin büyümesini doğrudan takip etmeyi mümkün kılar (Proffit ve ark., 2018, s.24-27). Yüz ölçümleri için altın standart olarak kabul edilen doğrudan antropometrinin dezavantajı ise zaman alıcı olması ve yüksek hasta uyumu gerektirmesidir (Topsakal ve Korkmaz, 2018).

2.1.2. Dolaylı Yüz İncelemeleri

Antropometrik incelemelerin dolaylı bir uygulaması sayılabilecek bu incelemeler, bireylerden kayıtlar alındıktan sonra gerçekleştirilir.

2.1.2.1. Sefalometrik İnceleme

Sefalometrik radyografiler, Broadbent tarafından 1931 yılında yeni bir radyolojik görüntüleme tekniği olarak tanıtılmıştır (Broadbent, 1931). İkinci Dünya Savaşı sonrasında yaygınlaşan bu yöntem, maloklüzyonların sadece yanlış diş yerleşiminden değil, aynı zamanda çene ilişkilerinden kaynaklandığını ortaya koymuştur. Sefalometri sayesinde, çene büyümesinin ortodontik tedavi ile değiştirilebildiğini görmek de mümkün olmuştur (Proffit ve ark., 2018, s.7). Ricketts (1961) sefalometrinin amaçlarını anomaliyi karakterize etmek, farklı zamanlarda çekilen radyografileri mukayese etmek, çeşitli dental veya iskeletsel sınıflandırmalar yapmak ve anomaliyi diğer hekimlerle paylaşmak şeklinde açıklamıştır (Ricketts, 1961). Ortodontik teşhis ve tedavi planlamasında önemli bir yere sahip olan sefalometrik radyografiler, kraniyofasiyal yapıların iki boyutlu görüntüleridir. Bu radyografik görüntülerden posteroanterior sefalometrik radyografiler dikey ve yatay yönlerde yüz hakkında bilgi verirken, lateral sefalometrik radyografiler sagittal ve dikey yönlerde yüz hakkında bilgi verir. Ve ayrıca projeksiyon hatası olarak adlandırılan bir bozukluğu da içerirler (Mupparapu, 2005). Bu radyografiler, elde edilmelerinin kolay olmasının yanı sıra klinikte tedavi durumunun anında değerlendirilmesine ve bireylerin büyüme süreçlerinin takip edilmesine olanak sağlaması açısından büyük avantaja sahiptir. Yumuşak doku profilinde zaman içinde meydana gelen değişiklikler sefalometrik incelemelerle tespit edilebilir (Burstone, 1959).

2.1.2.2. Fotoğrafik İnceleme

Yüz fotoğrafları, uzun yıllardır ortodontik teşhis amacıyla toplanan kayıtlarının standart bir parçası olmuştur (Proffit ve ark., 2018, s188). Ortodontide yüz fotoğrafları, yüz oranlarını ve ortodontik tedavi sürecindeki ilerlemeyi değerlendirmek için kullanılır (Stoner, 1955). Ortodonti hastaları için teşhis maksadıyla önerilen rutin yüz fotoğraf kayıtları Şekil 2.1'de gösterilmiştir. Bu fotoğraflar, birey istirahat pozisyonunda ve

gölümseme esnasında cepheden, profilden ve oblik açılardan çekilir (Graber ve ark., 2022, s248-252).



Şekil 2.1. Ortodontideki rutin fotoğraf kayıtları.

Farklı açılardan çekilebilen ve kısa sürede elde edilebilen fotoğraflar, yüzün doğal ve gerçekçi görünümünü yansıtır. Fotoğrafların sefalometriye göre avantajı, yumuşak dokuların daha detaylı kaydedilebilmesi ve değerlendirilebilmesidir (Payne, 2013). Ayrıca, sefalometride olduğu gibi, fotoğraflarda da bir büyütme faktörü mevcuttur. Ancak sefalometride sabit bir büyütme faktörü varken, fotoğraf çekiminde kullanılan lens ve bireyin lense olan uzaklığı gibi faktörler dolayısıyla fotoğraflarda değişken bir büyütme faktörü söz konusudur (Gavan ve ark., 1952).

Öte yandan yüz incelemeleri için standart bir fotoğraflama ve analiz yöntemi bulunmamaktadır. Fotoğraflama işlemi birçok farklı ekipmanla, birçok farklı çekim koşulunda ve birçok farklı ayar altında gerçekleştirilebilir. Ayrıca birçok farklı yazılım ile düzenleme ve analiz yapmak mümkündür.

Yüz Cephe İstirahat Fotoğrafları

Birey istirahat halindeyken yüzün karşıdan fotoğrafının çekilmesiyle elde edilir. Bu fotoğraf türü yüz formunu belirlemek, yüz simetrisini incelemek ve yüz oranlarını

değerlendirmek için kullanılır. Buna ek olarak, bu fotoğrafların çekiminde dikkat edilmesi gereken birtakım hususları Prof. Dr. Ümit Gazilerli (1999) şöyle açıklamıştır: Cepheden fotoğraf çekerken önce kamera hazırlanmalı sonra hasta hazırlanmalıdır. Baş ve yüzdeki birtakım anatomik noktalar fotoğrafta görülmelidir. Özellikle kız çocuklarında tragion ve trichion noktalarının görünmesi için saçlar yüzün ön kısmından geriye doğru atılmalıdır. Yine kulakların resimde görülebilmesi için saçlar kulak arkasına atılarak kulağın açıkta kalması sağlanmalıdır. Hasta, Frankfurt düzlemi yere paralel ve orta aksiyel düzlem yere dik olacak şekilde konumlandırılmalıdır. Hasta ağzını kapalı, dudaklarını ve yüz kaslarını gevşek tutmalı ve lense bakmalıdır. Kamera, film düzlemi yere dik ve filmin üst ve alt sınırları yere paralel olacak şekilde tutulmalıdır. Kamera lensi ile birey arasındaki mesafe her seferinde sabit tutulmalı, böylece büyütme faktörü her seferinde aynı olmalıdır (Gazilerli, 1999).

Cephe İstirahat Fotoğraflarının İncelenmesi

Cephe fotoğraflarının incelenmesi, yatay ve dikey yüz oranlarının ve simetrisinin incelenmesiyle başlar. Yüz formu bitemporal, bizigomatik, bigonial ve bimental genişliklerin yüz uzunluğuna oranı ile belirlenir. Yüz formu kareden üçgene, kısıdan uzuna ve dardan geniş kedar farklı şekillerde tanımlanabilir. Yüz simetrisi de her zaman kontrol edilir. Minör asimetriler birey tarafından her zaman fark edilmeyebilir ancak ortodontik tedavinin ilerleyen aşamalarında dikkatlerini çekebilir. Yüz asimetrilerini tespit etmek için orta hattaki cilt noktaları kalemle işaretlendikten sonra frontal ve submental kayıtlar alınarak değerlendirilebilir (Meneghini ve Biondi, 2012).

Yüz formu


Yüz formlarının çeşitliliği sınırsız olsa da basit bir değerlendirme ile temel bir yüz şekli kategorizasyonu elde edilebilir. Genel yüz şekli yuvarlak, kare ve üçgen olarak kategorize edilir. Dikey yönde yüz yüksekliği azalmış, normal veya artmış olarak sınıflandırılır. Yatay yüz yüksekliği de geniş, normal veya dar olarak sınıflandırılır.

Yüz yüksekliği ve yüz genişliği arasındaki ilişki yüz harmonisi için önemlidir. Yüz yüksekliği ve genişliği konusunda çeşitli oranlardan bahsedilebilir. Zigomatik noktalardan ölçülen yüz genişliği, vertex'ten menton'a kadar ölçülen yüz yüksekliğinin yaklaşık %60'ına karşılık gelmektedir. Bizigomatik genişlik, trichion ve mentondan ölçülen yüz yüksekliğinin yaklaşık %70-75'ine eşittir. Bitemporal genişlik bizigomatik genişliğin %80-85'ine karşılık gelmektedir. Bigonial genişlik bizigomatik genişliğin %70-75'ine eşittir. Nasiondan mentona kadar ölçülen yüz yüksekliğinin bizigomatik genişliğe oranı yüz indeksi olarak adlandırılır. Kollmann tarafından tanımlanan bu ölçüm, antropometride yüzleri sınıflandırmak için kullanılır. Dolikoproskopik yüz tipi, yatay yönde geniş ve dikey yönde nispeten düşük yükseklikte bir yüzü tanımlar. Mezoproskopik yüz tipi ortalama yüz tipidir. Leptoproskopik yüz tipi, dikey yönde uzun ve nispeten dar olan bir yüzü tanımlar (Naini, 2011, s.131-133). Buna ek olarak dolikoproskopik yüzler çoğunlukla vertikal maksiller yetersizlik, masseter hiperplazisi, artmış gonial açı, büyük çene ve sınıf II derin kapanış maloklüzyonu ile ilişkiliyken leptoproskopik yüzler çoğunlukla vertikal maksiller fazlalık, dar burun, ön-arka yönde mandibular yetersizlik, azalmış gonial açı, küçük çene, derin üst damak ve anterior açık kapanış ile ilişkilidir (Reyneke ve Ferretti, 2012).

Yüzün Yatay Yön Oranları

Yüzdeki beşler kuralı, yüzün yatay yöndeki oranlarını değerlendirmek için kullanılan bir yöntem olup yüzü yatay yönde beş eşit parçaya bölerek incelemektedir. Şekil 2.2'de numaralarla işaretlenen bölgelerin açıklaması sırayla verilecektir. İncelemede interkant al genişlik alar taban genişliğine eşit olmalıdır. Nazal dorsumun genişliği, alar taban genişliğinin yaklaşık yarısı kadar olmalıdır. Her iki irisin medial kenarları ağız köşeleriyle çakışmalıdır. Alt çenenin genişliği ve şekli yüzün geri kalanıyla uyum içinde olmalıdır. Gonion, gözün dış kantusundan dik olarak çizilen çizgi ile

çakışmalıdır. Ayrıca bigonial genişlik genellikle bizigomatik genişlikten %30 daha az olmalıdır. Beşler kuralı Şekil 2.2’de gösterilmiştir (Reyneke ve Ferretti, 2012).




Şekil 2.2. Beşler kuralı.

Yüzün Dikey Yön Oranları

Yüz, Şekil 2.3’te gösterildiği gibi, trichion, glabella, subnazal ve menton noktalarına paralel olan yatay çizgilerle 3 dikey parçaya ayrılır. Estetik olarak uyumlu bir

yüzde bu üç bölüm yaklaşık olarak aynı uzunlukta olmalıdır. Üst üçlü trichion ve galebella noktalarından, orta üçlü glabella ve subnasal noktalardan, alt üçlü ise subnasal ve menton noktalarından oluşur. Ayrıca yüzün alt üçte birlik kısmı subnazaleden vermillion hattına kadar olan üçte birlik kısım ile vermillion hattından mentona kadar olan üçte ikilik kısımdan oluşur. Labiomental kıvrım ise alt dudak ve çene ucu bölgesini eşit iki parçaya böler. Üçler kuralı Şekil 2.3'te gösterilmiştir(Reyneke ve Ferretti, 2012).




Şekil 2.3. Üçler kuralı.

Simetri

Yüz asimetrisi değerlendirilirken öncelikle asimetrinin mandibuladan, maksilladan veya bu yapıların kombinasyonundan kaynaklanıp kaynaklanmadığı belirlenmelidir (Reyneke ve ark., 1997). Yüz simetrisi değerlendirmesi için yüz orta

hattındaki dokular referans olarak alınmalıdır. Bu dokular glabella, burun dorsumu, burun ucu, kolumella, üst dudak filtrumu, maksiller dış orta hattı, mandibular dış orta hattı, alt dudak ve çene ucudur (Reyneke ve Ferretti, 2012). Üst dudak filtrumu ve tüberküllerin orta noktasına karşılık gelen Cubid's Bow noktası, yarık dudak veya üst dudağı bozan şiddetli burun asimetrisi gibi istisnai durumlar dışında yüzün orta hattında yer alır. Bu nokta ve yumuşak doku glabella noktasından geçen çizgi yüz orta hattını oluşturur. Yüz orta hattı referans noktaları Şekil 2.4'te gösterilmiştir (Naini, 2011, s.168-169).



Şekil 2.4. Yüz orta hattı referans noktaları.

2.1.2.3. Üç Boyutlu Görüntülemelerle İnceleme

Stereofotogrametri

Stereofotogrametri, bireyin daha kapsamlı ve doğru bir şekilde değerlendirilmesini sağlamak için eski fotogrametrik tekniklerden geliştirilmiştir.

Stereofotogrametri, eş düzlemlere yerleştirilmiş iki kamera ile farklı açılardan çekilen görüntülerden üç boyutlu bir yüz modelinin oluşturulduğu tekniktir. Aynı zamanda üç boyutlu yumuşak doku taslağını kaydetmek için kullanılan ilk tekniktir. Stereofotogrametrinin ilk klinik kullanımı, Thalmann-Degan tarafından ortodontik tedavilerden sonra hastaların yüzündeki değişiklikleri kaydetmek için gerçekleştirilmiştir (Burke ve Beard, 1967). Bilgisayar teknolojisindeki ilerlemelerle birlikte, yeni nesil bilgisayar destekli stereo-fotogrametrik teknikler ortaya çıkmıştır. Bu gelişmeler sayesinde kesit yakalama ve inşa prosedürleri daha hızlı, basit ve doğru bir hale gelmiştir (Hajeer ve ark., 2004). Stereofotogrametrinin avantajları arasında gelişmiş tekrarlanabilirlik, yüksek uzaysal çözünürlük, iyonize radyasyon içermemesi ve morfometrik ölçümlerden nicel ölçümler yapılabilmesi sayılabilir (Bernini ve ark., 2020). Yansıtıcı alanlar, kaş ve saç gibi bölgeler ve kayıt sırasında bireyin hareketi gibi faktörler yüz kaydının doğruluğunu bozabilir. Ayrıca tarayıcı aşırı kavisli ve yansıtıcı yüzeylere nüfuz edemediği için göz ve kulak gibi yapılardan iyi görüntü elde edilmesi mümkün olmayabilir (Karatas ve Toy, 2014).

Bilgisayarlı Tomografi İncelemesi

Bilgisayarlı tomografi cihazı ilk kez 1972 yılında ticari olarak üretilmiştir. Kraniyofasiyal cerrahi işlemler için ilk simülasyon yazılımı 1986 yılında geliştirilmiştir (Hajeer ve ark., 2004). Vücudun kesitsel görüntülerini oluşturmak için X ışınlarını kullanan bilgisayarlı tomografi cihazları konik ışınlı ve konvansiyonel olmak üzere 2 gruba ayrılır. Sıklıkla konik ışınlı tomografi cihazları dentofasiyal bölgeyi görüntülemek için kullanılır. Bilgisayarlı tomografi görüntülemenin avantajları, görüntülerin gerçek ölçekte olması ve büyütme artefaktlarından arındırılmış olması, baş konumlandırma hatalarının görüntü oluşturulduktan sonra düzeltilebilmesi olarak sıralanabilir (Graber ve ark., 2022, s220). Bilgisayarlı tomografinin dezavantajları arasında, yüksek maliyetli

olması, her hastanede bulunmaması, kesitlerden uzak olan lezyonların atlanma ihtimali, restorasyonların neden olduğu artefaktlar ve radyasyon miktarının yüksek olması sayılabilir. Bu dezavantajlara ek olarak, yumuşak dokuların görüntülenmesi diğer görüntüleme tekniklerine kıyasla yetersizdir (Harorli ve ark., 2006, s.214).

Üç Boyutlu Lazer Görüntüleme

Üç boyutlu lazer tarama görüntüleme, ortodontide yumuşak doku yüz analizi için kullanılan non-invaziv bir yöntemdir (Hajeer ve ark., 2004). Yüz yumuşak dokusunun yakalanması için geliştirilen lazer tarama, 3 boyutlu görüntüler üretir ve bilgisayarlı bir rekonstrüksiyon modeli oluşturur. Ortodontik tedavilerin yanı sıra özellikle ortognatik cerrahi tedavilerinin planlanması ve değerlendirilmesinde faydalıdır.

Lazer tarama prosedürünün bazı dezavantajları vardır. Tarama işlemi yavaş ve zaman alıcıdır. Tarayıcı hastayı kaydederken hastanın bir dakika veya daha uzun süre hareketsiz kalması gerekir. Bu da görüntü bozulmasına yol açabilir. Lazerin büyümekte olan bireylerde kullanımı, göz üzerindeki olası zararlı etkileri nedeniyle risklidir. Yumuşak doku yüzeyinin cihaz tarafından yakalanamaması olasıdır ve bu da referans noktalarının tespitini zorlaştıran bir faktördür (Karatas ve Toy, 2014).

Üç Boyutlu Yüz Morfometri Görüntüleme

Üç boyutlu yüz morfometri sistemi, kamera bağlantılı iki kızılötesi cihazdan, donanım işaretleyicilerin gerçek zamanlı tespitini ve koordinat sisteminde referans noktalarının üç boyutlu rekonstrüksiyonunu sağlayan bir yazılımdan oluşur (Ferrario ve ark., 1996). Referans noktaları yüz üzerinde tespit edilir ve 2 milimetrelik yarım küre şeklindeki yansıtıcı belirteçlerle kaplanır. Belirteçleri aydınlatmak için stroboskop adı verilen ultraviyole bir cihaz kullanılır. Belirteçlerin yüze yerleştirilmesi işlemi oldukça zaman alıcı ve zahmetlidir. Referans noktalarının tespitinin tekrarlanabilirliği çok zor ve şüphelidir. Kayıt sırasında yüz ifadesindeki değişiklikler hata oranını artırır. Bu sistemle yüz yumuşak dokusunun doğal görünümünü gösteren modeller oluşturulamamaktadır.

Sonuç olarak bu sistemi ortodontik tedavi hakkında karar vermek, hastalarla iletişim kurmak veya ortodontistler ile cerrahlar arasında iletişim kurmak için kullanmanın akıllıca olmadığı bildirilmiştir (Karatas ve Toy, 2014).

Video Görüntüleme

Video görüntüleme, dolaylı yöntemlerdeki statik ölçümler yerine yüz yumuşak dokularının dinamik ölçümleri için kullanılır (Payne, 2013). Standart bir yüz fotoğrafı, bir bireyin gülümsemesinin yaklaşık 1/125 saniyelik pozlamasını temsil eder. Gülümseme esnasında ortaya çıkan sorun, dudakların gülümseme işlemine hareketsiz olarak başlaması ve çok kısa bir süre içinde hareket etmesidir. Görüntü bu dinamik sürecin içerisinde bir noktada kaydedilir. Bu kayıt, bireyin tutarlı ve tekrarlanabilir gülümsemesini her zaman doğru bir şekilde temsil etmeyebilir. Dijital videografi ile gülümseme ve konuşmanın dinamik kaydı elde edilebilir. Dijital video kayıtları ile konuşma ve gülümseme sırasında ön dişlerin pozisyonunun kaydedilmesi önemlidir. Video klipler tekrar oynatılarak gülümseme ve kesici diş konumlandırması gözden geçirilebilir. Bu dinamik görüntüleme, klinisyene gülümsemeyi baştan sona görselleştirme ve gülümseme sırasında en tutarlı kesici diş konumunu görme fırsatı verir (Graber ve ark., 2022, s.251-252).

2.2. Yapay Zeka

2.2.1. Yapay Zeka ve Tarihçesi

Bilgisayar ve akıllı makinelerdeki gelişiminin öncüleri, 17. yüzyılda Pascal'ın hesap makinesini ve Leibnitz'in karekökler gibi gelişmiş aritmetik fonksiyonlar içeren makinesini icat etmesi, 19. yüzyılda Babbage'ın delikli kartlarla beslenen mekanik hesap makinesini icat etmesi ve İngiliz matematikçi George Boole'un YZ'daki birçok uygulamanın temeli olan sembolik mantığı geliştirmesi ve 20. yüzyılda Russell'ın Boole cebirini geliştirmesi sembolik mantığı kodlamasıdır. Alan Turing gelecekte YZ olarak adlandırılacak olan şeyin kurucularından biri olmuştur. Makinelerin zekası hakkında fikirler geliştiren Turing, makinelerin problem çözmede kullanabileceği algoritmalar üretmiş ve makinelerde zekanın varlığını kanıtlamak için Turing Testini geliştirmiştir. YZ ismini ilk kez 1950'lerde kullanan John McCarthy, aynı zamanda YZ için Lisp isimli orijinal bir programlama dili icat etmiştir (van Dijk ve Williams, 1990).

1956 yazında McCarthy ve meslektaşları Hanover'deki Dartmouth Koleji'nde bir çalıştay yapılmasını önermiştir. Bilim insanlarının bir yaz boyunca birlikte çalışmalarını halinde makinelerle ilgili birçok sorunun çözümünde önemli ilerlemeler kaydedileceğini düşünmüşlerdir (McCarthy ve ark., 2006). Çalıştaya, McCarthy ve meslektaşları Minsky, Rochester ve Shannon'ın yanı sıra dama oynayan bir program üreten IBM (International Business Machines Corporation) mühendisi Arthur Samuel, MIT'den (Massachusetts Institute of Technology) Ray Solomonoff, Allen Newell ve Herbert Simon da katılmıştır (Nilsson, 2018). Bu çalıştay, YZ isminin ortaya çıkmasına neden olduğu için önemlidir. Ayrıca çalıştaya katılan mühendisler daha sonra YZ'nin babaları olarak anılmıştır.

1960 yılından sonra YZ konusunda, akıllı makinelerin üretiminde birçok gelişme olmuştur. 1965 yılında Joseph Weizenbaum, Eliza adlı sanal konuşma robot yazılımını geliştirdi (Weizenbaum, 1966). 1966'da Stanford Üniversitesinde ilk mobil robot Shakey

üretilmiştir (Nilsson, 1984). 1981’de IBM tarafından ilk kişisel bilgisayar üretilmiştir (O’Regan, 2016). 1993 MIT YZ laboratuvarında Cog isimli insansı robot üretilmiştir (Brooks ve ark., 1999). 1997 yılında IBM tarafından geliştirilen Deep Blue adlı bilgisayar, dünya satranç şampiyonu Garry Kasparov’u bir satranç karşılaşmasında yenmiştir (Campbell ve ark., 2002). 1986 yılından bu yana Honda, insansı robotların geliştirilmesi üzerinde çalışmakta olup 2000 yılından sonra geliştirdiği insansı robot Asimo’yu tanıtmıştır (Shigemi, 2019). 2011 yılında Apple YZ destekli sanal asistan Siri’yi tanıtmıştır (Galeso, 2017).

2.2.2. Yapay Zeka Tanımı ve Alt Alanları


YZ, farklı araştırmacılar tarafından birçok kez tanımlanmıştır. YZ kurucularından McCarthy, YZ’yı “akıllı makineler üretme bilimi ve mühendisliği” olarak tanımlamıştır (McCarthy, 2004). YZ, insanların yapabildiklerini bilgisayarlara yaptırabilme çabası olarak da tanımlanmıştır (Pospelov, 1990). YZ’nın en kapsamlı tanımlarından biri, “bir bilgisayarın ya da bir makinenin insanlara özgü nitelikler olan akıl yürütme, anlam çıkarma, genelleme yapma ve geçmiş deneyimlerden öğrenme gibi işlevleri yerine getirme yeteneğidir” tanımıdır (Nabiyev, 2021, s.27).

YZ’nın amacı, insanlarla aynı yetenek yelpazesine sahip robotlar ve yazılımlar üretmektir. YZ sınıflandırması, insansı ve akılcı yaklaşıma sahip bir zekayı tanımlamaktadır. Bu bağlamda YZ tanımları için dört ana başlık öne çıkmaktadır: İnsan gibi düşünen, insan gibi davranan, akılcı düşünen ve akılcı davranan sistemler. Bu başlıkların destekleyicileri Tablo 2.2’de gösterilmiştir (Russell ve Norvig, 2010, s.2).

Tablo 2.2. Yapay zeka tanımlarının savunucuları.

İnsan Gibi Düşünen	İnsan Gibi Davranan	Akılcı Düşünen	Akılcı Davranan
Richard Bellmann	Ray Kurzweil	Eugene Charniak	Nills Nilsson
John Haugeland	Elaine Rich	Drew McDermott	David Poole
	Kevin Knight	Patrick Winston	

Bu YZ başlıkları arasında "insan gibi davranan" yapay zekaya örnek olarak Turing Testi verilebilir. 1950 yılında Alan Turing tarafından önerilen bu test, bir sorgucunun, teste katılan kişinin insan mı yoksa bilgisayar mı olduğunu bilmeden bir dizi yazılı soru sorduğu bir testtir. Turing testi Şekil 2.5'te şematize edilmiştir (Turing, 1956). Sorgucu, aldığı yanıtlardan karşıdakinin bilgisayar olup olmadığını tespit edemezse, bilgisayarın testi geçtiği kabul edilir (Russell ve Norvig, 2010, s.2-3).



Şekil 2.5. Turing testi.

YZ, daha anlaşılır olması için doğal zeka ile karşılaştırılmıştır. Doğal zekaya sahip insanlar bir şeyleri kolayca unuturken, YZ kalıcı olarak bir bilgisayarda depolanır. YZ kolayca kopyalanabilir ve paylaşılabılırken, doğal zekanın aktarılması için eğitim gerekir. YZ maliyetli olmasına rağmen, bilgisayarları farklı alanlarda kullanmak, nitelikli bir insanı eğitmekten daha ekonomik olacağı düşünülmektedir. YZ sistematik olarak tutarlıdır, ancak duyguları olan doğal zeka tutarsız ve değişken olabilir. YZ belgelenebilirken, doğal zekanın ulaştığı kararın nasıl ve hangi varsayımlardan geldiğini

belirlemek zor olabilir ve unutulabilir. YZ, şu ana kadar sıraladığımız özellikler bakımından doğal zekadan üstün görünse de doğal zeka yaratıcı ve yenilikçidir. Oysa YZ yenilikçi değildir. Doğal zeka, duyuları aracılığıyla edindiği deneyimleri kullanma ve geliştirme yeteneğine sahiptir, ancak YZ’da sembolik girdiler nedeniyle bu deneyimler yetersiz kalabilir. Ayrıca, doğal zekanın en önemli avantajı, muhakeme ve deneyim kullanarak sorunları hızlı bir şekilde çözme yeteneğidir (Nabiyev, 2021, 28-34).

YZ’nın farklı alanlarda ortaya çıkan problemlerin çözümü için geliştirilmiş alt alanları bulunmaktadır. Bu alt alanlar, bir problemin çözümünde tek başına kullanılabileceği gibi birkaç alt alan birlikte kullanılarak çözüm sağlanabilir. YZ alt alanları Şekil 2.6’da gösterilmiştir (Nabiyev, 2021, s.27-66).



Şekil 2.6. Yapay zeka alt alanları makine öğrenmesi.

Makine öğrenmesi, algoritmaların görevlerini kod kullanarak yerine getirmesi yerine, sağlanan verilerden örüntüleri öğrenerek görevleri yerine getirmesi için eğitildiği bir YZ alt alanıdır (Erickson ve ark., 2017). Makinelerin kendi zekalarını sergileme yeteneği olarak da adlandırılan YZ’nın amacı, sorunları çözmek için verilerden öğrenebilen makineler geliştirmektir. Makine öğreniminin amacı, insan rehberliği olmadan sorunları çözebilmeleri için makinelerin verilerden öğrenme sürecini kolaylaştırmaktır (Khanagar ve ark., 2021).

Temelde denetimli ve denetimsiz olmak üzere iki farklı makine öğrenmesi türü vardır. Denetimli öğrenmede veriler etiketlenir ve girdiler bilgisayara bir eğitim kümesi olarak verilir. Denetimsiz öğrenmede ise veriler etiketlenmeden bilgisayara aktarılır. Denetimsiz öğrenmede, algoritma belirli bir hedefe sahip olmadan verinin ne tür bir desene sahip olduğunu bulmaya çalışır. Denetimsiz öğrenme bu nedenle insan öğrenmesine daha yakındır. Denetimli öğrenmede ise, etiketli verilerle eğitilen modelin hedefi belirli iken, denetimsiz öğrenmede modelin hedefi belirsizdir (Gürsakal, 2017).

Makine öğrenmesinde, mevcut verileri üç parçaya bölmek standart bir uygulamadır. Veriler bir eğitim kümesi, bir doğrulama kümesi ve bir test kümesi olacak şekilde üçe ayrılır. Eğitim kümesi, sinir ağının parametrelerini eğitmek ve iyileştirmek için kullanılır. Doğrulama kümesi, eğitim süreci boyunca modelin performansını izlemek ve model seçimi yapmak için kullanılır. Modelin tüm parametreleri ayarlandıktan sonra, modelin test kümesi üzerindeki performansı ölçülür. Test kümesi, çalışmanın sonunda nihai modelin performansını raporlamak için kullanılır (Chartrand ve ark., 2017).


2.2.3. Yapay Sinir Ağları

Yapay sinir ağları (YSA), yapay nöronlar aracılığıyla sinyalleri hesaplayan bir dizi algoritmadır. YSA'nın amacı insan beyni gibi işlev gören sinir ağları oluşturmaktır (Khanagar ve ark., 2021). Haykin'e göre YSA, deneyime bağlı bilgiyi depolamaya ve kullanmaya dayalı bir işlemci olarak tanımlanmaktadır. Bu iki özellik insan beynine benzemektedir. Bilgi, öğrenme sürecinde ağ tarafından elde edilir ve sinir hücreleri arasındaki bağlantılar olan sinaptik ağırlıklar bilgiyi depolamak için kullanılır (Kubat, 1999).

YSA, birbirleriyle bağlantılı yapay sinir hücrelerinden oluşur. Biyolojik sinir hücreleri modellenerek geliştirilen yapay sinir hücrelerinde, bilgi işleme süreci nöronlarda gerçekleşir. Sinyaller nöronlar arasındaki bağlantılar aracılığıyla iletilir. Her

bir bağlantının belirli bir ağırlık değeri bulunmaktadır. Bir nöronun net çıktısı, net girdisinin bir aktivasyon fonksiyonundan geçirilmesi sonucu oluşur (Hamzaçebi, 2021).

YSA bir girdi katmanı, bir çıktı katmanı ve bu iki katman arasında bir veya daha fazla gizli katmandan oluşur. Girdi katmanı, verileri alan nöronların bulunduğu katmandır. Çıktı katmanı, ağı sonuçlarını çıktı olarak veren nöronlardan oluşan son katmandır. Gizli katmandaki nöronlar sinyallerini önceki katmanlardan alır. Bir nöron işlevini yerine getirdiğinde, çıktısını bir sonraki katmanın nöronlarına gönderir. Bahsi geçen katmanlar Şekil 2.7’de gösterilmiştir (Hamzaçebi, 2021).



Şekil 2.7. Yapay sinir ağı yapısı.

YSA, örneklerden öğrenen bir öğrenme modeli olarak düşünülebilir. YSA ile bir karar verilebilmesi için öncelikle ağı eğitilmesi gerekir. Eğitim sonrasında sinir ağı eksik bilgileri işleyerek bir sonuca ulaşabilir. Ayrıca hatalara karşı toleranslıdır (Nabiyev, 2021, s.582-600).

2.2.4. Derin Öğrenme

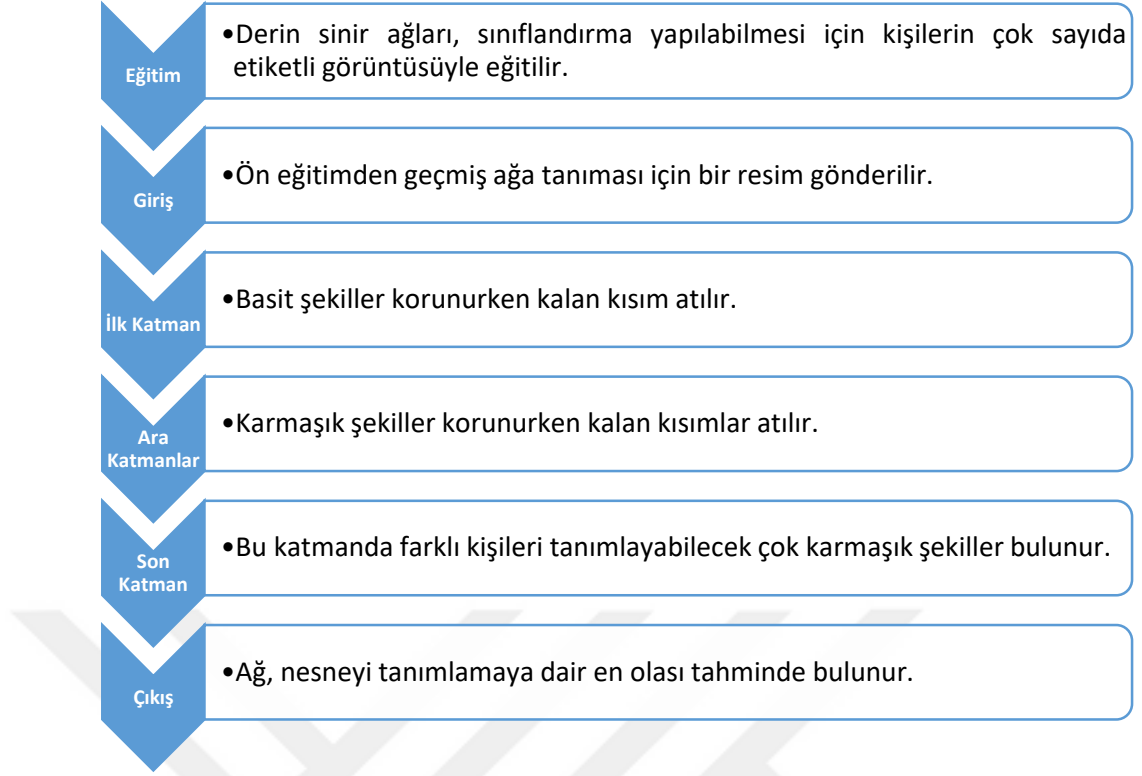
DÖ, çok katmanlı sinir ağlarını kullanan bir makine öğrenmesi türüdür. DÖ, geleneksel makine öğrenmesi yöntemlerindeki kodlanmış kurallardan öğrenme yerine verilerin sembollerinden otomatik olarak öğrenir. Esnek yapısı sayesinde ham veriden

öğrenme gerçekleştirilebilirken, verinin büyüklüğüne göre tahmin doğruluğu da artar (Yılmaz, 2021). DÖ'nin amacı, özellik tespitini iyileştirmek için kalıpları otomatik olarak tanımlayan bir sinir ağı oluşturmaktır (Khanagar ve ark., 2021). Şekil 2.8'de YZ'nın öğrenmeye ulaşan alt kümeleri gösterilmiştir.



Şekil 2.8. Yapay zeka alt kümeleri.

YSA içerisinde birçok DÖ yaklaşımı bulunmakta olup kullanım alanları farklıdır. İleri beslemeli sinir ağı (Feedforward Neural Networks veya FNN), işlemsel veriler üzerinde çok iyi sonuçlar verirken, Evrişimli sinir ağı (ESA) görüntü işlemede başarılıdır. Ses veya metin gibi sıralı verilerin işlenmesi için Tekrarlayan sinir ağı (Recurrent Neural Networks) daha iyi sonuçlar elde etmektedir. Ayrıca önışleme, boyut indirgeme, öznitelik çıkarma ve sınıflandırma gibi alt aşamalarının tek bir ağda birleşmiş olması, DÖ'nin önemli bir özelliğidir (Elmas, 2021). Görüntü işlemenin bir alt alanı olan görüntü tanıma, Şekil 2.6'da gösterilen aşamalar tamamlanarak derin sinir ağı kullanılarak gerçekleştirilir.



Şekil 2.9. Görüntü tanımanın temel adımları.

2.2.4.1. Derin Öğrenme Mimarileri

ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (IBÖGTY), her yıl elliden fazla kurumun katıldığı, milyonlarca görüntüyü içeren büyük ölçekli nesne tanıma ve kategorizasyon yarışmasıdır. Bu yarışma 2010 yılından beri düzenlenmektedir (Russakovsky ve ark., 2015). DÖ mimarilerinin bu yarışmalarda nesne tanıma elde ettiği başarılı sonuçlar, DÖ algoritmalarını popüler hale getirmiştir. Derin öğrenme mimarilerine örnek olarak LeNet, AlexNet, ZFNet, GoogleNet, ve ResNet verilebilir.

LeNet: LeCun tarafından geliştirilmiştir ve ilk evrişimli yapay sinir ağı olarak bilinir. LeCun ve ark. (1998) bu ağı banka çeklerinin üzerinde yazan numaraları tanımlamak için geliştirmiş ve LeNet adını vermişlerdir (Lecun ve ark., 1998).

AlexNet: 2012 yılında gerçekleştirilen IBÖGTY’de AlexNet DÖ mimarisi birinci olmuştur (Hinton ve ark., 2012). AlexNet’in görüntü tanımadaki hata oranını %26’dan %15’e düşürmüş olması AlexNet’i DÖ mimarileri arasında popüler hale getirmiştir.

ZFNet: 2013 IBÖGTY yarışması için geliştirilmiş bir mimaridir ve %11.2 hata oranı ile yarışmanın birincisi olmuştur. ZFNet'in mimarisi, AlexNet mimarisi üzerinde yapılan değişikliklerle geliştirilmiştir (Fu ve ark., 2018).

GoogleNet: Inception modülünü içeren GoogleNet, %5.7 gibi düşük bir hata oranına ulaşmış ve 2014 yılında IBÖGTY'nın kazananı olmuştur (Szegedy ve ark., 2015).

ResNet: %3.6 gibi düşük bir hata oranına ulaşan bu mimari, 2015 yılında IBÖGTY'nın birincisi olmuştur (Russakovsky ve ark., 2015). Bu yarışmadaki başarılı performansı insan doğruluğunu geride bırakmıştır (Alom ve ark., 2019). Ayrıca ResNet mimarisi, diğer DÖ mimarilerine kıyasla daha fazla katmana sahiptir ve bu da onu diğer mimarilerden ayırmaktadır (Elhassouny ve Smarandache, 2019).

Pixel-in-Pixel Net (PIPNet) : Jin ve ark. (2020) yüz referans noktalarını tespit etmek amacıyla PIPNet ismindeki mimariyi tanıtmışlardır. Bu mimari PIP regresyonu, komşu regresyon modülü ve müfredatla kendi kendine eğitim olmak üzere üç modülden oluşmaktadır (Jin ve ark., 2020)

Tablo 2.3. Derin öğrenme algoritmaları(Doğan, 2018).

Yıl	DÖ Algoritması	Geliştirici	Hata oranı	Parametre Sayısı
1998	LeNet	Yann LeCun		60 bin
2012	AlexNet	Alex Krizhevsky Geoffrey Hinton Ilya Sutskever	% 15.3	60 milyon
2013	ZFNet	Matthew Zeiler Rob Fergus	%14.8	
2014	GoogleNet	Google	%6.67	4 milyon
2015	ResNet	Kaiming He	%3.6	

R-CNN, Fast R-CNN ve Faster R-CNN, nesne tanımlama için geliştirilmiş oldukça başarılı DÖ modelleridir. Nesne tanımlama, bir görüntüdeki bir nesnenin konumunu ve sınırlarını belirleme işlemidir. R-CNN modelinde eğitim süreci çok aşamalı, maliyetli ve zaman alıcıdır. Ve nesne tanıma işlemi yavaştır.

Fast R-CNN, daha hızlı eğitim ve test aşamaları, yüksek algılama kapasitesi, disk depolama alanına ihtiyaç duymadan önbelleğe alma yeteneği olan hızlı ve güvenilir bir modeldir (Girshick, 2015). Faster R-CNN, iki modülden oluşan bir modeldir. İlk modül, bölgeler öneren tam evrişimli bir ağıdır. İkinci modül önerilen bölgeleri kullanır ve hızlı R-CNN dedektörünü içerir. Tüm sistem, nesne tespiti için tek ve birleşik bir ağıdır (Ren ve ark., 2015).

2.2.4.2. Derin Öğrenme Kütüphaneleri

Derin ağların geliştirilmesinde ve verimliliğinde kütüphane olarak adlandırılan birçok açık kaynaklı yazılım aracından yararlanılmaktadır. Bunlardan en aktif ve popüler olanları Caffe, CNTK, TensorFlow, Keras ve Torch kütüphaneleridir. Bu kütüphaneler Java, C#, C++ ve Python gibi çeşitli programlama dilleriyle entegre edilebilmektedir.

Caffe, Berkeley Vision and Learning Center (BVLC) tarafından geliştirilmiş ve 2014 yılından bu yana açık kaynak kodlu hale getirilmiştir. Python ve MATLAB programlama dillerinde lisanslı bir kütüphanedir (Jia ve ark., 2014). Görüntü işleme ve DÖ üzerine yazılmış olan Caffe kütüphanesinin en önemli özelliği, önceden eğitilmiş modellere sahip olmasıdır (Toğaçar ve Ergen, 2019).

CNTK, Microsoft Research tarafından geliştirilen ve birçok popüler sinir ağını destekleyen birleşik hesaplamalı bir ağ yazılımıdır (Shi ve ark., 2016).

TensorFlow, Google tarafından geliştirilen açık kaynak kodlu bir kütüphanedir (Shi ve ark., 2016). Genellikle görüntü işlemede kullanılan sayısal hesaplamalar için kullanılır (Toğaçar ve Ergen, 2019).

Keras, Python programlama dili ile yazılmış bir öğrenme kütüphanesidir ve TensorFlow kütüphanesi üzerinde çalışabilme özelliğine sahiptir (Toğaçar ve Ergen, 2019).

Torch, makine öğrenmesi algoritmalarındaki bileşenler için veri yapıları sağlayan ve matematiksel işlemleri içeren bir bilimsel hesaplama yazılımıdır (Shi ve ark., 2016). Python programlama dili tarafından desteklenen Torch kütüphanesi, karmaşık problemleri daha basit hale getiren ve problemin çözümü için algoritmayı daha hızlı ve esnek bir yapıya dönüştüren bir kütüphanedir (Toğaçar ve Ergen, 2019).

2.2.5. Diş Hekimliğinde Yapay Zeka

Diyabetik retinopatiyi tespit edebilen ilk YZ sisteminin (Abramoff ve ark., 2018) FDA (Amerikan Gıda ve İlaç Dairesi) tarafından onaylanmasının ardından sağlık alanında YZ uygulamaları yaygınlaşmaya başlamıştır. Teknolojinin hızla gelişimi ve dijital diş hekimliğinin yaygınlaşmasına paralel olarak diş hekimliğinde YZ uygulamaları artmaktadır. Başarılı YZ uygulamaları, bize yakın gelecekte diş hekimliği alanında teşhis ve tedavi planlamasında rutin bir araç olabileceğini göstermektedir. YZ ve sinir ağlarının tanı ve tedavi aşamalarında zaman kazandıracağı, verimliliği ve doğruluğu artıracığı düşünülmektedir.

Diş hekimliği alanında, hasta anamnez bilgileri, restoratif ve periodontal çizelgeler, tanı bilgileri, radyolojik görüntüler, ağız içi ve yüz fotoğrafları gibi birçok veri kümesi bulunmaktadır. Bu veri kümeleri makine öğrenmesi modelleri için girdi olarak kullanılmakta ve görüntü yorumlama, teşhis-tedavi önerileri ve hastalık tahminleri gibi çıktıların üretilmesine yardımcı olmaktadır. Ortaya çıkan modellerin doğruluğu, büyük ölçüde makine öğrenmesi sisteminin öğrenme süreci için kullanılan girdi verilerinin türüne, sayısına ve kalitesine bağlıdır (Pethani, 2021).

YZ ve YSA, dental radyolojide tanı, tedavi planlaması ve tedavi sonuçlarının tahminini kolaylaştırmak için yaygın olarak kullanılmaktadır. Radyografi görüntüleri, geniş veri kümeleri olmaları nedeniyle YZ çalışmaları için uygun bir alan haline gelmiştir. Panoramik radyografilerden dişlerin tespit edilmesi ve otomatik olarak

numaralandırılması (Tuzoff ve ark., 2019), ağız kanserlerinin erken evrede tespit edilerek prognozun iyileştirilmesine katkı sağlanması (Tan ve ark., 2016), mandibular üçüncü molar dişlerin mandibular sinir ile ilişkisinin tespit edilmesi (Vinayahalingam ve ark., 2019), temporomandibular eklem hastalıklarından eklem içi düzensizliklerin alt tiplerinin ayırıcı tanısı ve sağlıklı eklem belirlenmesi (Bas ve ark., 2012), panoramik radyografilerden maksiller sinüzit tespiti (Murata ve ark., 2019), osteoporoz teşhisi (Lee ve ark., 2020) ve çocuklarda tahmini yaş hesaplaması (Veleminska ve ark., 2013) amacıyla birçok başarılı YZ modeli geliştirilmiştir.

Restoratif diş hekimliğinde YZ algoritmalarının, diş çürüklerini ve restorasyonları tespit edebileceği ve çürük temizleme yöntemi seçimini kolaylaştırabileceği gözlenmiştir. Diş çürüklerinin periapikal radyografilerden (Lee ve ark., 2018a) ve bite-wing radyografilerinden teşhis edilmesinde (Yasa ve ark., 2021); diş restorasyonlarının panoramik radyografilerden tespit edilip sınıflandırılmasında iyi performans gösteren YZ modelleri geliştirilmiştir (Abdalla-Aslan ve ark., 2020). Diş çürüğü eliminasyonu sonrası streptococcus mutans miktarının öngörmek (Javed ve ark., 2020) ve kök çürüklerinin erken tespitini sağlamak (Hung ve ark., 2019) için YZ modelleri geliştirilmiştir.

Endodontide YZ, periapikal lezyonların radyolojik olarak tespitinde (Ekert ve ark., 2019; Pauwels ve ark., 2021), konik ışınlı bilgisayarlı tomografi görüntülerinde periapikal lezyonların tespit edilmesi ve patolojisinin saptanmasında (Orhan ve ark., 2020; Setzer ve ark., 2020), vertikal kök fraktürlerinin teşhisinde (Fukuda ve ark., 2020; Kositbowornchai ve ark., 2013), kök kanal sisteminin değerlendirilmesinde, diş pulpasının canlılığını tahmin edilmesinde, radyografide apikal foramenin konumunun doğru bir şekilde belirlenmesi ve çalışma uzunluğunun doğru bir şekilde tespit edilmesinde (Saghiri ve ark., 2012) ve re-treatment tedavilerinin başarı oranının tahmin edilmesinde (Aminoshariae ve ark., 2021) faydalı olacağı görülmüştür.

Dental cerrahide; ortognatik cerrahi planlamasında, diş çekimi sonrası komplikasyonların tahmininde, kemik lezyonu tespitinde ve implantolojik tedavi planlamasında diş hekimlerine yardımcı olabilir. Üçüncü molar dişlerin çekimi sonrası parestezi oluşumunun tahmin edilmesinde (Kim ve ark., 2021) ve post-operatif şişlik oluşumunun tahmin edilmesinde (Zhang ve ark., 2018), diş çekimi sonrası bifosfonat kullanımına bağlı osteoradyonekroz olasılığının öngörülmesinde (Kim ve ark., 2018), ortognatik tedavinin yüz çekiciliği ve tahmini yaş üzerindeki etkisinin değerlendirilmesinde (Patcas ve ark., 2019), cerrahi sonrası tahmini profil video kayıtlarının doğruluğu ve güvenilirliğinin ölçülmesinde (Lu ve ark., 2009), panoramik radyografilerden ameloblastoma ve odontojenik keratokistin ayrıcı tanısında (Liu ve ark., 2021), dental implant markalarının ve tedavi aşamalarının belirlenmesinde (Sukegawa ve ark., 2021), konik ışıklı bilgisayarlı tomografi görüntüleri kullanılarak başarılı implant planlamasında (Kurt Bayrakdar ve ark., 2021) kullanılan YZ modelleri geliştirilmiştir.

Periodontal tanıya yardımcı olmak için radyografik alveoler kemik seviyesinin ölçülmesinde (Lee ve ark., 2022), periodontitis safhalarının otomatik bir şekilde teşhis edilmesinde (Chang ve ark., 2020), periodontal hastalıklardan kaynaklanan kemik kaybının tespit edilmesinde (Krois ve ark., 2019) periapikal radyografilerde peri-implant kemik kaybının ölçülmesinde (Cha ve ark., 2021) kullanılan YZ modelleri geliştirilmiştir.

Renk tonu, doygunluk ve parlaklık gibi renk özelliklerinin tespit edilerek doğal diş rengine uygun restorasyonların yapılması (Chen ve ark., 2020), dişlerin numaralandırılarak dijital iş akışında kullanılması (Raith ve ark., 2017) ve periodontal prognozu zayıf dişlerin tespit edilmesi (Lee ve ark., 2018b) amacıyla geliştirilen YZ modelleri protetik diş hekimliğinde kullanım alanı bulmuştur.

2.2.6. Ortodontide Yapay Zeka Uygulamaları

Sefalometrik radyografiler, ortodontistler tarafından iskeletsel ilişkilerin kantitatif olarak değerlendirilmesi amacıyla alınır. Bu radyografilerle maksilla ve mandibulanın birbirleriyle, kafa tabanı ve dento-alveolar yapılarla ilişkisi incelenir. Bu radyografiler ayrıca, çocukların büyüme modelini belirlemek ve büyüme potansiyellerini tespit etmenin yanı sıra ortognatik cerrahi ihtiyacı olan hastaların tedavi planlamasında da kullanılır. Sefalometrik analiz için çizimler zaman alıcıdır ve anatomik referans noktalarının konumlandırılması bireyler arasında farklılık gösterebilir. Bu amaçla, daha kısa sürede daha kesin sonuçlar elde etmek için YZ kullanılarak birçok çalışma yapılmıştır. Bu çalışmalarda, DÖ modelleri genellikle klasik makine öğrenmesi tekniklerinden daha iyi performans göstermiştir (Mohammad-Rahimi ve ark., 2021).

Park ve ark. (2019), sefalometrik radyografileri kullanarak sefalometrik referans noktalarının otomatik olarak tanımlanması için güncellenmiş iki farklı DÖ algoritmasının verimliliğini ve doğruluğunu karşılaştırmıştır. Çalışmada You Only Look Once version 3 (YOLOv3) ve Single Shot Multibox Detector yöntemleri karşılaştırılmış ve YOLOv3'ün klinik uygulamalarda daha umut verici sonuçlar elde ettiği görülmüştür (Park ve ark., 2019).

Kunz ve ark. (2020), sefalometrik radyografilerde referans noktalarını otomatik olarak tanımlamak için geliştirdikleri DÖ tabanlı YZ algoritmasının, eğitilmiş bireylere benzer düzeyde yüksek doğruluk oranı gösterdiğini bildirmiştir (Kunz ve ark., 2020).

Ortodontik tedavi için diş çekimi ihtiyacının belirlenmesinde YZ'nin kullanılmasına yönelik çalışmalar yapılmıştır. Xie ve ark. (2010), ortodontik modeller ve lateral sefalometrik radyografiler kullanarak diş çekimlerinin gerekliliğini belirlemek için bir YSA modeli kullanmışlardır (Xie ve ark., 2010). Jung ve Kim (2016)'de lateral sefalometrik radyografileri kullanarak diş çekimi gerekliliğine karar vermek için uzman

sistemler kullanmışlardır (Jung ve Kim, 2016). Her iki çalışma da YZ uygulamalarının ortodontik tedavi amaçlı diş çekimi gereksinimini tahmin etmede etkili ve doğru olabileceğini göstermiştir (Khanagar ve ark., 2021).

Camcı ve Salmanpour tarafından yapılan çalışmada, karışık dişlenme dönemindeki sürmemiş mandibular kanin ve premolar dişlerin mezio-distal genişliklerini tahmin etmek için bir YSA modeli tasarlanmıştır. Elde edilen sonuçlar Moyers tablosu ile karşılaştırılmış ve DÖ modelinin sürmemiş dişler için tahmin performansının %49.5 olduğu ve bunun kabul edilebilir olduğunu raporlamışlardır (Camcı ve Salmanpour, 2022).

Gil ve ark. (2022) tarafından yapılan çalışmada, postero-anterior radyografilerde sefalometrik referans noktalarının otomatik olarak tanımlanmasının doğruluğu değerlendirilmiştir. Çalışmada farklı kalitedeki postero-anterior radyografi görüntüleri, çoklu merkezlerden elde edilmiştir. Geliştirilen ESA modelinin başarı tespit oranı %83.3 olarak bulunmuştur (Gil ve ark., 2022).

Thanathornwong tarafından yapılan bir çalışmada, ortodontik tedavi ihtiyacını değerlendirmek için bayesian ağı (BN) kullanılarak geliştirilen YZ modelinin yüksek doğruluk gösterdiği bildirilmiştir (Thanathornwong, 2018).

Ortognatik cerrahi tedavi, diğer tedaviler gibi doğru teşhis ve tedavi planlaması gerektirir. Arnett ve ark. (1993), ortodontik teşhis ve tedavi planlamasında hata yapılan hastalarda estetiğinin kötüleşebileceğini ve ciddi bir sorun oluşturabileceğini öne sürmüştür (Arnett ve Bergman, 1993). Bu açıdan diş hekimlerinin hastanın sorunlarını doğru analiz etmesi ve doğru tanıya ulaşması çok önemlidir. Choi ve ark. (2019), lateral sefalometrik radyografileri kullanarak vakanın cerrahi olup olmayacağına, olacaksa hangi tip cerrahi olacağına ve tedavinin diş çekimini içerip içermeyeceğine karar vermek için yeni bir YZ modeli geliştirdiklerini bildirmişlerdir. Modelin başarı oranı, gerçek tanı ile

YZ modelinin elde ettiği tanı karşılaştırılarak hesaplanmış ve hastanın ameliyat olup olmaması gerektiğine karar vermede %96, ameliyat türüne ve dış çekimine karar vermede ise %91 başarı oranına sahip olduğu bildirilmiştir (Choi ve ark., 2019). Bu çalışma, YZ modellerinin ortognatik cerrahi vakalarının teşhisinde kullanılabileceğini göstermektedir.

Büyüme-gelişimin ve kalan büyüme miktarının belirlenmesi için el-bilek ve sefalometrik radyografiler kullanılır. Hägg ve Taranger (1982), hastanın kronolojik yaşını belirlemenin kalan büyüme miktarını tahmin etmek için tek başına yeterli olmadığını ve bu nedenle çeşitli iskeletsel olgunlaşma indikatörlerinin geliştirildiğini belirtmişlerdir (Hagg ve Taranger, 1982). Kök ve ark. (2019), servikal vertebraların olgunlaşması sürecinden büyüme ve gelişimi belirlemek için YZ modelleri geliştirmişlerdir. Geliştirdikleri YSA modelinin büyüme ve gelişimi servikal vertebra olgunlaşmasına göre belirlemek için tercih edilebilir bir yöntem olduğunu bildirmişlerdir (Kok ve ark., 2019).

Yüz fotoğrafları, sefalometrik radyografiler gibi ortodontik teşhis ve tedavi planlamasında önemli bir yer tutmaktadır. Yüz fotoğraflarından yüz referans noktalarını tanımlamak ve analiz etmek için etkili ve otomatik bir aracın eksikliğini fark eden Rao ve ark. (2019), akıllı bir makine öğrenmesi yaklaşımı geliştirmiştir. Çalışmalarında, DÖ algoritması YOLO'nun yüz fotoğraflarında referans noktalarını tespit etmedeki etkinliğini ve doğruluğunu değerlendirmişlerdir. Oluşturdıkları sistemin etkili ve verimli olduğunu aynı zamanda referans noktalarının belirlenmesinin ve analiz edilmesinin hızlı ve güvenilir olduğunu bildirmişlerdir (Rao ve ark., 2019).

Rousseau ve ark. (2022) tarafından gerçekleştirilen bir çalışmada, makine öğrenmesi yöntemleri kullanılarak yapılan otomatik yüz analizinin doğruluğu, dikey boyutlar açısından değerlendirilmiştir. Dört farklı referans noktasını içeren ölçümler 45 hasta üzerinde gerçekleştirilmiştir. Referans noktaları arasındaki mesafeler, iki farklı

yöntem kullanılarak hesaplanmıştır. İlk yöntemde, mesafeler manuel olarak ölçülürken ikinci yöntemde yazılım kullanılarak otomatik olarak hesaplanmıştır. Manuel ve otomatik ölçüm sonuçlarının benzerlik gösterdiği bildirilmiştir (Rousseau ve Retrouvey, 2022).



3. MATERYAL VE METOT

Çalışmamıza, Atatürk Üniversitesi Diş Hekimliği Fakültesi Dekanlığı Etik Kurulu'nun 01/06/2021 tarih ve 05/2021 sayılı oturumunda 36 karar numarası ile etik onay verilmiş (Ek-3), çalışmanın bilimsel ve etik açıdan kabul edilebilir olduğuna mevcut üyelerin oy birliği ile karar verilmiştir. Çalışmamız Helsinki Bildirgesi prensiplerine uygun olarak yürütülmüştür.

Çalışmamız, metodolojik araştırmalar kapsamındadır. Çalışma evrenini, Atatürk Üniversitesi Diş Hekimliği Fakültesi Ortodonti Ana Bilim Dalı'na ait fotoğraf arşivinde bulunan yüz cephe istirahat fotoğrafları oluşturmaktadır. Araştırma evreninin büyüklüğü, DÖ modelinin test veri kümesi üzerindeki performansı değerlendirilerek belirlenmiştir. Eğitim veri seti, kabul edilebilir model performansı elde edilene kadar artırılmıştır.


Çalışmanın başlangıcında ışık, ortam, mesafe ve ekipman açısından tamamen standart koşullarda elde edilecek fotoğraflarla model eğitimi yapılması planlanmıştır. Ancak model eğitimi için oldukça fazla sayıda fotoğrafa ihtiyaç duyulduğu zaman içerisinde ortaya çıkınca arşiv fotoğrafları model eğitime dahil edilerek DÖ modelinin performansının yükselmesi sağlanmıştır. Arşivde yer alan fotoğrafların çoğu ISO:400'de ve otomatik program modunda çekilmiştir. Arşiv fotoğrafçılığı için kullanılan ekipman Tablo 3.1'de verilmiştir.

Tablo 3.1. Fotoğraf ekipmanları.

Ekipman	Marka
Fotoğraf Makinesi	: Canon EOS 70d
Lens	: Canon EFS 18-55 mm Macro 0.25m/0.8ft Lens
Flash	: Macro Ring Lite MR-14EX

Yüz hatlarının doğallığını maskeleyen makyajlı kişilerin, sakallı ve/veya bıyıklı kişilerin, saçları veya kulakları tamamen kapatan baş örtüsü takan kişilerin ve gözlük takan kişilerin fotoğrafları çalışmamıza dahil edilmemiştir.

Çalışmamızın yöntem aşamaları Şekil 3.1’de verilmiştir.




Şekil 3.1. Yöntem aşamaları.

3.1. Fotoğrafların Etiketlenmesi


Veri etiketleme, birçok makine öğrenimi ve DÖ yönteminin temelini oluşturan ve YZ modellerinin ham verileri tanıyarak doğru tahminler yapmasını sağlayan bir yöntemdir. Ek olarak ön işleme aşamasının önemli bir parçasıdır.

Arşivden seçilen uygun fotoğraflar, Şekil 3.2’de gösterilen CranioCatch (Eskişehir, Türkiye) etiketleme modülüne yüklenmiştir. Çalışmada kullanılan anatomik referans noktalarının isimleri modüle eklenmiştir. Etiketleme modülü kullanılarak yüz cephe istirahat fotoğraflarında 39 anatomik referans noktasını etiketlenmiştir. Tüm referans noktalarının yüz fotoğrafında etiketlenmesi, etiketleyicinin deneyimi ve kullanılan ekran büyüklüğü gibi faktörlere bağlı olarak genellikle 5 ila 10 dakika arasında tamamlanmaktadır. Çalışmada kullanılan anatomik referans noktaları (Naini, 2011, s.82-84) Tablo 3.2’de tanımlarıyla birlikte verilmiştir. Modül kullanılarak etiketlenmiş bir yüzün görüntüsü Şekil 3.4’te verilmiştir.



Şekil 3.2. Veri etiketleme modülünün görünümü.


Toplamda 2872 yüz fotoğrafında 39 anatomik referans noktası etiketlenmiştir. Bu fotoğrafların 2100'ü eğitim veri kümesi için ayrılırken, kalan 772 fotoğraf test veri kümesine dahil edilmiştir (Standart bir uygulama olarak, %10'luk bir test veri kümesinin kullanılması yaygındır. Çalışmada model performansının daha kapsamlı değerlendirilmesi için test veri kümesi daha geniş tutulmuştur).



Şekil 3.3. Veri kümesi dağılımı.

Tablo 3.2. Anatomik referans noktaları.

Referans Noktası	Tanım
1. Dış Kornea	: Sağ göz korneasının yatay düzlemde en distal noktası
2. İç Kornea	: Sağ göz korneasının yatay düzlemde en mesial noktası
3. Vertex	: Doğal baş pozisyonunda, başın en yüksek noktası
4. Trichion	: Alın ve saç çizgisinin orta hatta birleştiği nokta
5. Glabella	: Alnın kaş sırtları hizasında en belirgin orta hat noktası
6. Nasion	: Nazal radiks ve nazofrontal bölgenin orta hat üzerindeki birleşim noktası
7. Nasal Dorsum	: Burun sırtı, burnun ortasındaki nokta
8. Pronasale	: Burun ucunun en ön noktası
9. Nasal Taban	: Subnazal olarak da adlandırılan burnun üst dudakla birleştiği orta noktası
10. Cubid's Bow	: Filtrumun üst dudak vermilionu ile birleştiği ve dudak tüberküllerinin ortasındaki derin nokta
11. Pogonion	: Alt çene ucunun en ön ve orta noktası
12. Menton	: Alt çene ucunun en alt ve orta noktası
13. Sağ Frontotemporale	: Sağ frontal kemiğin temporal kreti üzerindeki en medial nokta
14. Sol Frontotemporale	: Sol frontal kemiğin temporal kreti üzerindeki en medial nokta
15. Sağ Zygion	: Sağ zigomatik arkın en dış noktası
16. Sol Zygion	: Sol zigomatik arkın en dış noktası
17. Sağ Orbitale	: Sağ orbital rimin palpe edilebilir en alt noktası
18. Sol Orbitale	: Sol orbital rimin palpe edilebilir en alt noktası
19. Sağ Gonion	: Sağ mandibular (gonial) açının en dış noktası
20. Sol Gonion	: Sol mandibular (gonial) açının en dış noktası
21. Sağ Mentale	: Sağ mental bölgenin lateral en alt noktası
22. Sol Mentale	: Sol mental bölgenin lateral en alt noktası
23. Sağ Exocanthion	: Sağ alt ve üst göz kapaklarının buluştuğu lateral kantus noktası
24. Sağ Endocanthion	: Sağ alt ve üst göz kapaklarının buluştuğu medial kantus noktası
25. Sol Endocanthion	: Sol alt ve üst göz kapaklarının buluştuğu medial kantus noktası
26. Sol Exocanthion	: Sol alt ve üst göz kapaklarının buluştuğu lateral kantus noktası
27. Sağ Pupil	: Sağ pupillanın merkez noktası
28. Sol Pupil	: Sol pupillanın merkez noktası
29. Sağ Ala Nasi	: Sağ alar konturün en dış noktası
30. Sol Ala Nasi	: Sol alar konturün en dış noktası
31. Sağ Chelion	: Sağ oral komissuranın en dış noktası
32. Sol Chelion	: Sol oral komissuranın en dış noktası
33. Üst Dudak Sağ Tüberkül	: Üst dudak sağ tüberkülünün tepe noktası
34. Üst Dudak Sol Tüberkül	: Üst dudak sol tüberkülünün tepe noktası
35. Üst Dudak Dip	: Üst dudağın alt dudakla temas ettiği stomion noktası
36. Alt Dudak Tepe	: Alt dudağın üst dudakla temas ettiği stomion noktası
37. Alt Dudak Dip	: Alt dudak vermilionu üzerindeki orta nokta
38. Sağ Kulak	: Sağ kulağın en dış noktası
39. Sol Kulak	: Sol kulağın en dış noktası



Şekil 3.4. Etiketlenen anatomik referans noktaları.

3.2. Model Eğitimi için Ön Hazırlık Aşaması

Tüm etiketlenmiş veriler etiketleme modülünden indirilir.

Verilerdeki etiketleme işleminden kaynaklanabilecek olası hatalar yazılan kodlarla kontrol edilir ve bulunan hatalar kodlar aracılığıyla düzeltilir. Bu işlem, gereksiz yere etiketlenmiş noktaları siler, eksik etiketlenmiş fotoğrafları kaldırır ve aynı fotoğraf

birden fazla kez etiketlenmişse fotoğrafları veri kümesinden kaldırır.

Modülden indirilen etiketleme koordinatlarını içeren JSON formatındaki veri, fotoğraflardaki noktaların isimleri ve koordinatları yazılarak “fotograf_adi.jpg x_1 y_1” şeklinde kaydedilir. 0 ile 1 arasında değişen x ve y değerleri, noktanın fotoğraf üzerinde yüzdesel olarak karşılık geldiği koordinatı göstermektedir. (Örneğin, eğer x değeri 1 ise, nokta fotoğrafın sağındadır.)

Fotoğraflar, kırılmadan 256x256 piksel giriş boyutuna yeniden boyutlandırılır.

Tablo 3.3. Veri hazırlık aşamasında kullanılan kütüphaneler.


Kütüphane	Fonksiyon
json	: Json formatında okuma ve yazma işlemleri için kullanılır.
opencv-python	: Fotoğraf okuma ve yazma işlemleri için kullanılır
matplotlib	: Fotoğraf görüntüleme ve gözle yapılan testler için kullanılır.
os, shutil	: İşletim sistemi klasör oluşturma ve silme otomasyonu için kullanılır
numpy	: Hızlı listeleme işlemleri için kullanılır
math	: Matematiksel hesaplamalar için kullanılır
natsort	: Belgeleri işletim sistemindeki sıraya göre listelemek için kullanılır

3.3. Derin Öğrenme Modeli Eğitim Aşaması

Çalışmamızda, Pixel-in-Pixel-Net mimarisi (Jin ve ark., 2020) ve omurga ağı olarak ResNet101 (He ve ark., 2015) mimarisi tercih edilmiştir. Aynı zamanda ResNet101 modeliyle önceden eğitilmiş ağırlıklar kullanılarak transfer öğrenme işlemi gerçekleştirilmiştir. Transfer öğrenme sürecinde, ilgili konu hakkında önceden eğitilmiş bir model elde edilir ve hedeflenen modele aktarılır (Yang ve Shami, 2020). ResNet101 mimarisi yavaş olmasına rağmen çok başarılı sonuçlar verdiği için omurga ağ olarak tercih edilmiştir.

Eğitim verileri yüklenmiş ve veri çoğaltma (data augmentation) uygulanmıştır. Veri çoğaltma işlemi, bir veri kümesini yapay olarak genişletmek ve veri kümesinin kullanılabilirliğini artırmak için kullanılır. Bu işlemler esasen aynı bulgunun farklı görünümünü sunar ve derin bir öğrenme algoritmasını daha sağlam ve genelleştirilebilir

olmasını sağlar (Do ve ark., 2020). Veri çoğaltma prosedürü Şekil 3.5'te (Jin ve ark., 2020) verilmiştir.




Şekil 3.5. Sırasıyla veri çoğaltma prosedürleri.

Tablo 3.4. Model eğitiminde uygulanan veri çoğaltma prosedürleri.

İşlem	Fonksiyon
translation	: Fotoğrafi x ve y ekseninde rastgele bir yönde ± 30 piksel öteler.
occlusion	: Fotoğrafta, uzun kenarı 100 pikseli aşmayan bir dikdörtgen, rastgele renklerle rastgele bir bölgeyi örter.
horizontal flipping	: Fotoğrafi yatay yönde rastgele döndürür.
rotation	: Fotoğrafi rastgele ± 30 derece döndürür.
blurring	: Fotoğrafın tamamını rastgele (maksimum 5 yarıçaplı Gauss bulanıklığı ile) bulanıklaştırır.
grayscale	: Fotoğrafi rastgele siyah-beyaz biçime dönüştürür.

Her YZ modelinde, problemleri çözmek için hiperparametrelerin hassas bir şekilde ayarlanması gerekir. Hiperparametrelerin seçiminin doğru yapılması, modelin performansı üzerinde doğrudan bir etkiye sahiptir. Hiperparametrelerin seçimi, makine öğrenmesi algoritmaları ve parametre optimizasyonları hakkında geniş bilgi gerektirir (Yang ve Shami, 2020).



Şekil 3.6. Model eğitimimizdeki hiperparametre değerleri.

Genel olarak, büyük bir veri kümesi sinir ağına tek seferde aktarılamaz. Bu nedenle veri kümesi bölünmelidir. “Evre sayısı” modelin tüm eğitim verileri boyunca bir kez ileri geri gitmesini ifade eder. Genellikle, bir modeli eğitmek için “Evre sayısı” işlemi birçok kez tekrarlanır. “Alt küme boyutu” bir ileri/geri geçişte kullanılan sabit sayıdaki eğitim verisini ifade eder. “Alt küme boyutu” veri kümesinin toplam boyutu, modeldeki ağırlık sayısı ve grafik işlemci biriminin kullanılabilir belleği dikkate alınarak belirlenir. Genellikle “alt küme boyutu”, 1-128 arasında değişir. “Alt küme boyutu” ne kadar yüksek olursa, o kadar fazla bellek alanına ihtiyaç duyulur. “Öğrenme oranı” modelin parametrelerinin ne kadar ayarlandığını denetleyen bir hiperparametredir. Uygun bir “öğrenme oranı” değeri ayarlamak önemlidir. “Öğrenme oranı” çok küçükse, model oldukça yavaş şekilde birleşecektir (Do ve ark., 2020).

Tablo 3.5. Eğitim aşamasında kullanılan kütüphaneler.


Kütüphane	Fonksiyon
pytorch ve PIPNet methodları	: Veri artırma metotları, veri yükleme ve model yükleme işlemleri için kullanılmıştır.
numpy	: Hızlı listeleme işlemleri için kullanılmıştır.
pillow, opencv-python	: Fotoğraf okuma ve yazma işlemleri için kullanılmıştır

3.4. Model Performansının Ölçüm Aşaması

Eğitim sonrası model tahminleri test verileri üzerinden okunur. Etiketlenen noktanın RGB renk kodları 256x256 piksel boyutundaki çıktı verilerine eklenir ve kaydedilir.

Çıktılar $x_1y_1, x_2y_2 \dots x_ny_n$ formatında etiketli noktaların koordinatlarını gösterir. Bu gösterim formatı 256*256 piksel boyutlu bir görüntü üzerindeki noktanın konumunu göstermektedir. Yazılan kod ile işaretlenen noktanın koordinatları, fotoğrafın orijinal boyutundaki gerçek koordinatlarına dönüştürülür.

Geliştirilen YZ modelinin tahminleri, eğitim veri setinde yer almayan test verileri üzerinde işaretlemeler yapacak şekilde düzenlenir. Araştırmacı tarafından test veri kümesinde işaretlenen noktaların koordinatları, model tarafından işaretlenen fotoğraf üzerine aktarılır. Geliştirilen model tarafından tahmin edilen mavi noktalar ve araştırmacı tarafından işaretlenen kırmızı noktalar, Şekil 3.6'da gösterilmiştir.




Şekil 3.7. Model tarafından tahmin edilen (mavi) ve araştırmacı tarafından işaretlenen noktalar (kırmızı).

İlgili referans noktası için işaretlenmiş mavi ve kırmızı noktalar arasındaki mesafe Şekil 3.8'de verilen formül kullanılarak hesaplanmıştır. Hesaplanan uzunluk piksel cinsinden olduğundan, piksel uzunlukları milimetrik uzunluklara dönüştürmek için Şekil 3.8'de gösterilen *iç ve dış kornea* noktaları kullanılmıştır. *Dış kornea* ve *iç kornea* noktaları arasındaki piksel uzunluğu 11.71 mm olarak alınmış ve hesaplamalar kalibre edilmiştir. (1 mm'nin kaç piksele eşit olduğunu bulmak için iki nokta arasındaki piksel değeri 11.71'e bölünmüştür.) Korneanın yatay çapını gösteren bu uzunluk için 390 kişiyi kapsayan bir çalışma referans alınmıştır (Rufer ve ark., 2005). Böylece, YZ modeli tarafından işaretlenen noktalar ile araştırmacı tarafından işaretlenen noktalar arasındaki mesafe milimetre değerine dönüştürülmüştür.

$$\text{İki nokta arasındaki uzaklık} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$$

Şekil 3.8. İki koordinat arası mesafe formülü.



Şekil 3.9. Dış ve iç kornea noktaları.

Tablo 3.6. Ölçüm aşamasında kullanılan kütüphaneler.

Kütüphane	Fonksiyon
numpy	: Hesaplamalarda hızlı liste işlemleri için kullanılmıştır
math	: Basit matematik hesaplamaları için kullanılmıştır
matplotlib	: Grafikler için kullanılmıştır
opencv-python	: Fotoğrafları okuma ve yazma işlemleri için kullanılmıştır

3.5. Derin Öğrenme Modelinin Performansının Değerlendirilmesi

Geliştirilen YZ modelinin performansını değerlendirmek için ortalama radyal hata (ORH), standart sapma (SS) ve başarı tespit oranı (BTO) ölçütleri kullanılmıştır. IEE Uluslararası Biyomedikal Görüntüleme Sempozyumu'nda, bu ölçütler sefalometrik filmlerde anatomik referans noktaları tespiti için kullanılmaktadır (Wang ve ark., 2015). Bu değerlendirme ölçütlerinin ayrıca, 2023 CEPHA29 Otomatik Sefalometrik Landmark Tespiti Yarışması'nda model performansını değerlendirmek için de kullanılacağı açıklanmıştır (Khalid ve ark., 2022).

3.5.1. Değerlendirme Metrikleri

3.5.1.1. Standart Sapma ile Birlikte Ortalama Radyal Hata

İlk değerlendirme kriteri, ortalama radyal hata ve standart sapmadan oluşmaktadır. Radyal hata (R), Şekil 3.9'daki formülde olduğu gibi hesaplanır. Yatay (x) ve dikey (y) koordinat sistemlerinde, Δx ve Δy değerleri model tarafından tahmin edilen noktanın konumu ile araştırmacı tarafından işaretlenen noktanın konumu arasındaki mesafedir.

$$R = \sqrt{\Delta x^2 + \Delta y^2}$$

Şekil 3.10. Radyal hata formülü.

ORH Şekil 3.10'daki formülde olduğu gibi hesaplanır.

$$ORH = \frac{\sum_{i=1}^N R_i}{N}$$

Şekil 3.11. Ortalama radyal hata formülü.

Standart sapma (SS) değeri Şekil 3.11'deki formülde olduğu gibi hesaplanır.

$$SS = \sqrt{\frac{\sum_{i=1}^N (R_i - ORH)^2}{N - 1}}$$

Şekil 3.12. Standart sapma formülü.

3.5.1.2. Başarı Tespit Oranı

İkinci değerlendirme kriteri, 1.0 mm, 1.5 mm, 2.0 mm, 2.5 mm, 3.0 mm ve 4.0 mm hassasiyet aralıklarına göre başarı tespit oranını hesaplayan bir metriktir. Hassasiyet aralığı, bahsedilen değer ve daha küçük sapma ile tespit edilen noktaları belirtmektedir.

Her bir nokta için, asıl araştırmacı tarafından model eğitiminde gerçekleştirilen etiketleme koordinatı ile DÖ modeli tarafından tahmin edilen koordinat arasındaki mesafe hesaplanır. Ve bu mesafenin doğruluk aralığı içinde olup olmadığı kontrol edilir. Mesafe belirlenen doğruluk aralığının altındaysa, geliştirilen modelin o aralıkta başarılı olduğu kabul edilir. İlgili oranın formülü Şekil 3.12’de verilmiştir.

$$p_z = \frac{\#\{j : \| L_d(j) - L_r(j) \| < z\}}{\#\Omega} \times 100\%$$

Şekil 3.13. Başarı tespit oranı.

L_d : Tespit edilen noktanın yerini gösterir.

L_r : Referans alınan noktanın yerini gösterir.

z : Değerlendirme aşamasında kullanılan milimetrik aralığı belirtir.

Ω : Yapılan tespit sayısının belirtir.

3.6. İstatistiksel Değerlendirme

Gruplar arasında karşılaştırma yapabilmek için asıl araştırmacı yaklaşık 110 yüz fotoğrafını model eğitimi için yapılan ilk etiketlemeden en az bir ay sonra ikinci kez etiketlemiştir. Ayrıca, Atatürk Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı’nda üç yıldır uzmanlık eğitimi alan ikinci bir araştırmacı da aynı fotoğrafları etiketlemiştir. Asıl araştırmacının model eğitiminde kullanılan etiketlemesi standart etiketleme kabul edilmiştir. Asıl araştırmacı etiketlemesi ve ikinci araştırmacı etiketlemesi standart kabul edilen etiketleme ile kıyaslanmıştır.

Karşılaştırmalarda asıl araştırmacının ikinci etiketlemesi, ikinci araştırmacının etiketlemesi ve DÖ modelinin genel tahminlerine ilişkin ortalama radyal hata, standart sapma ve başarı tespit oranları kullanılmıştır.

3.6.1. Ortalama Radyal Hataların Değerlendirilmesi

Çalışmamızda ortalama radyal hatalara ilişkin veriler GraphPad Prism versiyon 9.0 (GraphPad Software, Boston, MA) yazılımı kullanılarak analiz edilmiştir. Karşılaştırma grupları birinci araştırmacının etiketlemesi, ikinci araştırmacının etiketlemesi ve DÖ modeli genel tahminlerine dayanan standart sapma ve ortalama radyal hata değerlerini içermektedir.

Gruplar arası karşılaştırmalar için Tek Yönlü Varyans (Oneway Anova) Testi kullanılmıştır. Varyanslar eşit olduğu için çoklu karşılaştırma testlerinden (post-hoc) biri olan Sidak yöntemi kullanılmıştır. Elde edilen sonuçlar, $p < 0.05$ anlamlılık düzeyi kabul edilerek değerlendirilmiştir.

3.6.2. Başarı Tespit Oranlarının Değerlendirilmesi

Çalışmamızda başarı tespit oranlarına ilişkin veriler, SPSS paket programı versiyon 26 (IBM Corporation, Chicago, IL) kullanılarak analiz edilmiştir. Çalışma grupları, 2.0 mm hassasiyet aralığındaki asıl araştırmacı etiketlemesi, ikinci araştırmacı etiketlemesi ve DÖ modeli genel tahminlerinin başarı tespit oranlarından oluşmaktadır. Grupların normallik varsayımını kontrol etmek için çarpıklık ve basıklık değerleri incelenmiştir. Ayrıca, gruplar arasındaki ilişkiyi değerlendirmek için Pearson korelasyon analizi testi uygulanmıştır. İstatistiksel anlamlılık düzeyi $p < 0.05$ kabul edilmiştir. Ek olarak, Cronbach's Alpha güvenilirlik analizi hesaplanmıştır.

4. BULGULAR

4.1. Ortalama Radyal Hata ve Standart Sapma Değerlerine Ait Bulgular

4.1.1. Derin Öğrenme Modeli Tahminlerine Ait Bulgular

Geliştirilen DÖ modelinin tüm tahminlerine ait genel ortalama radyal hata değeri, ortalama standart sapma değeri ve başarı tespit oranı Tablo 4.1’de verilmiştir.


Tablo 4.1. Derin öğrenme modelinin genel ORH, SS ve BTO değerleri.

ORH (mm)	SS (mm)	BTO (%)					
		1.0 mm	1.5 mm	2.0 mm	2.5 mm	3.0 mm	4.0 mm
1.82	2.55	43.93	61.96	73.17	80.89	85.83	91.98

4.1.1.1. Ortalama Radyal Hata

Geliştirilen DÖ modeli tahminlerine ait ortalama radyal hata değeri 1.82 ± 2.55 mm olarak bulunmuştur. 39 referans noktası arasından, 0.56 ± 0.64 mm radyal hata değeri ile *sağ pupil* noktasının en düşük hata değerine sahip nokta olduğu görülmüştür. 0.64 ± 0.78 mm’lik radyal hata değeri ile bu noktayı *sol pupil* noktası takip etmektedir. *Sağ mentale* noktasının ise 3.38 ± 2.24 mm radyal hata değeriyle en yüksek hata değerine sahip olan nokta olduğu görülmüştür.

DÖ modeli tahminlerine ilişkin ortalama radyal hata değerleri (mm) tablosu Şekil 4.1’de verilmiştir.




Şekil 4.1. Derin öğrenme modeline ilişkin ortalama radyal hata değerleri (mm).

4.1.1.2. Başarı Tespit Oranı

DÖ modeli tahminleri 1.0 mm, 1.5 mm, 2.0 mm, 2.5 mm, 3.0 mm ve 4.0 mm hassasiyet aralıklarında sırasıyla %43.93, %61.96, %73.17, %80.89, %85.83 ve %91.98 başarı tespit oranlarına ulaşmıştır. 1.0 mm, 1.5 mm, 2.0 mm, 2.5 mm, 3.0 mm hassasiyet aralıklarında sırasıyla %89.64, %97.41, %99.09, %99.61 ve %99.74 başarı tespit oranlarıyla DÖ modelinin en başarılı tahmin ettiği noktanın *sağ pupil* noktası olduğu görülmüştür. 4.0 mm hassasiyet aralığında ise, %100 başarı tespit oranı ile *cubid's bow* ve *üst dudak dip* noktaları tahmin edilen en başarılı noktalar olurken, bu noktaları %99.87 başarı tespit oranı ile *sağ pupil* noktası takip etmiştir. 1.0 mm hassasiyet aralığında, %10.75 başarı tespit oranıyla *sol zygion* noktası DÖ modeli tarafından en az başarı ile tahmin edilen nokta olurken 1.5 mm, 2.0 mm, 2.5 mm, 3.0 mm ve 4.0 mm aralıklarında sırasıyla %20.98, %30.31, %40.54, %49.48 ve %65.93 başarı tespit oranı ile bu aralıklarda en az başarı ile tahmin edilen nokta *sağ mentale* noktası olmuştur.

Tablolarımız altı hassasiyet aralığına ilişkin verileri içermektedir. Sefalometrik referans noktaları tespiti için klinik uygulamada kabul edilebilir hassasiyet aralığının 2.0 mm olduğu ifade edilmiştir (Wang ve ark., 2015). Tabloyu sadeleştirmek amacıyla Şekil 4.2'de DÖ modeli tahminlerinin 2.0 mm hassasiyet aralığındaki başarı tespit oranları verilmiştir.



Şekil 4.2. Derin öğrenme modeli tahminlerine ilişkin 2.0 mm hassasiyet aralığındaki başarı tespit oranları (%).

Geliştirilen DÖ modelinin tüm referans noktaları tahminlerine ilişkin ortalama radyal hata değeri, ortalama standart sapma değeri ve başarı tespit oranı Tablo 4.2'te verilmiştir.

Tablo 4.2. Derin öğrenme modeli tahminlerine ait ORH, SS ve BTO değerleri.

Referans Noktaları	ORH (mm)	SS (mm)	BTO (%)					
			1.0 mm	1.5 mm	2.0 mm	2.5 mm	3.0 mm	4.0 mm
Sol Ala Nasi	1.04	0.82	58.68	82.25	91.97	97.02	98.19	99.09
Sağ Ala Nasi	1.09	1.32	55.96	80.18	90.80	97.15	98.19	99.22
Sol Chelion	1.09	0.93	55.31	79.15	90.41	95.85	97.67	99.35
Sağ Chelion	1.10	0.77	55.18	78.11	89.38	95.21	97.80	99.74
Cubid's Bow	0.84	0.53	70.21	90.28	96.50	98.45	99.48	100.0
Sol Endocanthion	1.03	2.08	62.18	85.10	94.56	98.19	99.35	99.61
Sağ Endocanthion	1.01	1.32	60.88	83.81	94.30	97.54	99.09	99.61
Sol Exocanthion	1.10	1.75	60.88	81.48	90.03	95.34	98.06	99.09
Sağ Exocanthion	1.04	1.56	62.05	83.55	92.88	96.37	97.93	99.22
Dış Kornea	0.79	2.28	85.62	92.23	94.56	95.85	95.98	96.24
İç Kornea	0.68	1.64	84.97	93.65	96.50	96.76	96.76	96.76
Sol Frontotemporale	2.68	4.49	15.03	28.89	45.21	60.23	70.47	85.23
Sağ Frontotemporale	2.87	2.10	11.92	25.26	40.03	51.04	61.53	77.98
Glabella	1.33	1.54	42.75	69.56	84.59	91.97	95.73	98.45
Sol Gonion	3.13	4.80	18.52	34.97	46.76	57.25	64.25	74.74
Sağ Gonion	2.71	4.65	25.13	37.82	52.33	63.73	71.89	82.38
Alt Dudak Dip	1.11	0.67	49.09	77.85	90.54	96.11	98.32	99.74
Alt Dudak Tepe	0.88	1.09	68.78	89.77	96.50	98.83	99.09	99.61
Sol Mentale	2.86	2.11	16.58	30.05	40.67	52.85	62.44	76.55
Sağ Mentale	3.38	2.24	11.92	20.98	30.31	40.54	49.48	65.93
Menton	1.49	1.91	36.14	62.44	78.76	88.86	94.56	98.19
Nasal Taban	0.92	1.23	68.78	88.99	95.21	97.28	98.58	99.61
Nasal Dorsum	1.91	1.27	28.37	45.73	59.72	71.76	82.51	92.36
Nasion	1.76	1.32	30.18	50.39	68.39	79.02	85.10	94.43
Sol Orbitale	2.32	2.07	17.49	32.25	48.83	65.54	77.07	89.77
Sağ Orbitale	1.91	1.77	25.13	42.75	62.18	78.11	86.14	94.69
Sol Kulak	3.37	9.00	26.81	42.75	52.72	61.01	67.75	78.63
Sağ Kulak	3.30	8.93	27.33	40.80	51.55	60.23	68.78	79.02
Pogonion	1.89	1.18	23.06	41.97	60.23	76.81	85.36	95.47
Pronasale	1.37	1.09	40.54	65.54	80.44	91.58	95.73	98.70
Sol Pupil	0.64	0.78	86.66	96.24	98.70	99.09	99.48	99.74
Sağ Pupil	0.56	0.64	89.64	97.41	99.09	99.61	99.74	99.87
Üst Dudak Sağ Tüberkül	1.14	0.84	53.11	75.52	88.21	93.78	96.37	99.09
Üst Dudak Sol Tüberkül	1.14	0.76	51.68	76.30	88.21	93.78	96.50	99.74
Üst Dudak Dip	0.81	0.51	71.63	90.54	97.02	99.35	99.61	100.0
Trichion	2.71	2.35	17.36	33.68	48.96	60.36	68.39	80.83
Vertex	2.66	3.44	21.11	36.66	49.09	61.01	69.56	81.99
Sol Zygion	3.12	2.43	10.75	22.02	33.16	46.24	57.64	73.83
Sağ Zygion	2.58	1.69	15.67	29.40	44.17	55.05	66.97	82.51

4.1.2. Araştırmacının İkinci Kez Etiketlemesine Ait Bulgular

Araştırmacının aynı veriyi tekrar etiketlemesi ile ilk etiketleme arasındaki farka ilişkin genel ortalama radyal hata değeri, ortalama standart sapma değeri ve başarı tespit oranı Tablo 4.2’de verilmiştir.

Tablo 4.3. Araştırmacıya ait genel ORH, SS ve BTO değerleri.

ORH (mm)	SS (mm)	BTO (%)					
		1.0 mm	1.5 mm	2.0 mm	2.5 mm	3.0 mm	4.0 mm
1.55	4.20	66.54	75.16	80.28	84.09	86.53	90.81

4.1.2.1. Ortalama Radyal Hata

Araştırmacının aynı verileri yeniden etiketlemesinde tüm noktalara ait genel ortalama radyal hata değeri 1.55 ± 4.20 mm olarak bulunmuştur. 39 referans noktası arasından *dış kornea* noktasının, 0.32 ± 1.28 mm ortalama radyal hata değeri ile hata oranı en düşük nokta olduğu görülmüştür. 0.41 ± 2.2 mm ortalama radyal hata değeri ile bu noktayı *iç kornea* noktasının takip ettiği görülmüştür. 5.1 ± 15.67 mm hata değerine sahip olan *sol gonion* noktasının ise hata oranı en yüksek nokta olduğu görülmüştür.

4.1.2.2. Başarı Tespit Oranı

Araştırmacı aynı verileri yeniden etiketlediğinde, 1.0 mm, 1.5 mm, 2.0 mm, 2.5 mm, 3.0 mm ve 4.0 mm hassasiyet aralıklarında sırasıyla %66.54, %75.16, %80.28, %84.09, %86.53 ve %90.81 başarı tespit oranına ulaşmıştır. 1.0 mm hassasiyet aralığında %98.06 başarı tespit oranı ile *dış kornea* noktasının en yüksek başarı ile işaretlenen nokta olduğu görülmüştür. 1.5 mm hassasiyet aralığında %99.03 başarı tespit oranı ile en yüksek başarı ile işaretlenen noktaların *dış kornea*, *iç kornea*, *nasal taban*, *sol pupil*, *sağ pupil* ve *üst dudak dip* noktaları olduğu görülmüştür. 2.0 mm, 2.5 mm, 3.0 mm ve 4.0 mm aralıklarında ise %100 başarı tespit oranı ile en yüksek başarı ile işaretlenen noktanın *üst dudak dip* noktası olduğu görülmüştür. 1.0 mm, 1.5 mm, 2.0 mm, 2.5 mm, 3.0 mm ve 4.0

mm hassasiyet aralıklarında sırasıyla %27.18, %28.16, %31.07, %37.86, %42.72 ve %48.54 başarı tespit oranı ile en az başarı ile işaretlenen noktanın *sol zygion* noktası olduğu görülmüştür.

Tablo 4.4. Araştırmacının yeniden etiketlemesine ait ORH, SS ve BTO değerleri.

Referans Noktaları	ORH (mm)	SS (mm)	BTO (%)					
			1.0 <u>mm</u>	1.5 <u>mm</u>	2.0 <u>mm</u>	2.5 <u>mm</u>	3.0 <u>mm</u>	4.0 <u>mm</u>
Sol Ala Nasi	0.42	1.33	87.38	97.09	98.06	98.06	99.03	99.03
Sağ Ala Nasi	0.61	3.25	90.29	97.09	98.06	99.03	99.03	99.03
Sol Chelion	0.89	4.43	81.55	93.20	98.06	99.03	99.03	99.03
Sağ Chelion	0.66	1.96	78.64	92.23	96.12	97.09	99.03	99.03
Cubid's Bow	0.52	1.94	90.29	96.12	98.06	98.06	99.03	99.03
Sol Endocanthion	0.62	3.56	91.26	97.09	99.03	99.03	99.03	99.03
Sağ Endocanthion	0.64	3.46	89.32	93.20	98.06	99.03	99.03	99.03
Sol Exocanthion	0.73	1.45	69.90	76.70	81.55	93.20	97.09	97.09
Sağ Exocanthion	0.93	1.56	66.02	71.84	83.50	90.29	94.17	98.06
Dış Kornea	0.32	1.28	98.06	99.03	99.03	99.03	99.03	99.03
İç Kornea	0.41	2.20	94.17	99.03	99.03	99.03	99.03	99.03
Sol Frontotemporale	3.15	10.80	43.69	56.31	70.87	81.55	85.44	96.12
Sağ Frontotemporale	2.75	7.96	32.04	43.69	55.34	64.08	72.82	86.41
Glabella	1.16	6.52	76.70	85.44	89.32	92.23	93.20	98.06
Sol Gonion	5.10	15.67	42.72	48.54	51.46	61.17	66.02	74.76
Sağ Gonion	2.41	4.04	55.34	60.19	65.05	68.93	70.87	75.73
Alt Dudak Dip	0.40	0.69	82.52	92.23	96.12	99.03	99.03	100.0
Alt Dudak Tepe	0.75	2.87	82.52	93.20	98.06	98.06	98.06	98.06
Sol Mentale	2.01	4.61	45.63	55.34	66.99	72.82	77.67	88.35
Sağ Mentale	4.01	4.61	39.81	40.78	40.78	43.69	49.51	61.17
Menton	1.39	7.66	67.96	85.44	95.15	97.09	98.06	99.03
Nasal Taban	0.75	4.45	90.29	99.03	99.03	99.03	99.03	99.03
Nasal Dorsum	1.59	2.38	52.43	61.17	70.87	76.70	79.61	89.32
Nasion	1.84	2.83	53.40	61.17	65.05	69.90	72.82	85.44
Sol Orbitale	2.95	2.87	36.89	39.81	42.72	48.54	55.34	64.08
Sağ Orbitale	2.38	2.67	43.69	50.49	57.28	61.17	64.08	73.79
Sol Kulak	1.85	4.28	59.22	67.96	75.73	80.58	82.52	86.41
Sağ Kulak	1.49	4.01	67.96	78.64	82.52	85.44	85.44	89.32
Pogonion	1.57	2.45	44.66	66.99	76.70	82.52	84.47	93.20
Pronasale	1.13	2.26	61.17	72.82	83.50	87.38	89.32	96.12
Sol Pupil	0.73	4.50	92.23	99.03	99.03	99.03	99.03	99.03
Sağ Pupil	0.57	3.24	96.12	99.03	99.03	99.03	99.03	99.03
Üst Dudak Sağ Tüberkül	0.74	1.38	74.76	91.26	94.17	97.09	98.06	99.03
Üst Dudak Sol Tüberkül	0.82	3.15	78.64	91.26	95.15	96.12	99.03	99.03
Üst Dudak Dip	1.19	9.10	90.29	99.03	100.0	100.0	100.0	100.0
Trichion	1.78	1.66	36.89	45.63	59.22	71.84	78.64	91.26
Vertex	2.26	9.11	43.69	62.14	70.87	81.55	89.32	92.23
Sol Zygion	4.22	4.25	27.18	28.16	31.07	37.86	42.72	48.54
Sağ Zygion	3.02	5.10	39.81	43.69	51.46	56.31	63.11	72.82

Araştırmacının aynı verileri yeniden etiketlemesine ilişkin ortalama radyal hata değeri, ortalama standart sapma değeri ve başarı tespit oranı Tablo 4.4'te verilmiştir.

4.1.3. İkinci Araştırmacı Etiketlemesine İlişkin Bulgular

Asıl araştırmacı etiketlemesi ile ikinci araştırmacının etiketlemesi arasındaki farka ilişkin tüm noktalara ait genel ortalama radyal hata değeri, ortalama standart sapma değeri ve başarı tespit oranı Tablo 4.5'de verilmiştir.

Tablo 4.5. İkinci araştırmacı etiketlemesine ait genel ORH, SS ve BTO değerleri.

ORH (mm)	SS (mm)	BTO (%)					
		1.0 mm	1.5 mm	2.0 mm	2.5 mm	3.0 mm	4.0 mm
3.35	3.50	29.83	44.79	54.70	61.03	66.11	72.18

4.1.3.1. Ortalama Radyal Hata

İkinci araştırmacının etiketlemesine ilişkin genel ortalama radyal hata değeri 3.35 ± 3.50 mm olarak bulunmuştur. 39 referans noktası arasından 0.63 ± 0.35 mm radyal hata değeri ile *dış kornea* noktasının hata oranı en düşük nokta olduğu görülmüştür. 0.68 ± 0.27 mm ortalama radyal hata değeri ile bu noktayı *iç kornea* noktası takip etmiştir. Sağ frontotempore noktasının 8.88 ± 11.22 mm radyal hata değeri ile hata oranı en yüksek nokta olduğu görülmüştür.

4.1.3.2. Başarı Tespit Oranı

İkinci araştırmacının etiketlemesinde 1.0 mm, 1.5 mm, 2.0 mm, 2.5 mm, 3.0 mm ve 4.0 mm hassasiyet aralıklarında sırasıyla %29.83, %44.79, %54.70, %61.03, %66.11 ve %72.18 başarı tespit oranına ulaşmıştır. 1.0 mm hassasiyet aralığında %88.33 başarı tespit oranı ile en yüksek başarı ile işaretlenen noktaların *dış kornea*, *iç kornea*, *sol pupil* ve *sağ pupil* noktaları olduğu görülmüştür. 1.5 mm hassasiyet aralığında %100 başarı tespit oranını ile en yüksek başarı ile işaretlenen noktanın *iç kornea* noktası olduğu görülmüştür. 2.0 mm hassasiyet aralığında *iç kornea* noktasına ek olarak %100 başarı

tespit oranını *dış kornea* ve *nasal taban* noktaları göstermiştir. Bu üç noktaya ek olarak 2.5 mm hassasiyet aralığında *cubid's bow noktası* da %100 başarı tespit oranına ulaşmıştır. 3.0 mm hassasiyet aralığında ise daha önce %100 başarı tespit oranına ulaşmış noktalara ek olarak *sol ala nasi*, *sağ ala nasi* ve *sol chelion* noktaları %100 başarı tespit oranına ulaşmıştır. 4.0 mm hassasiyet aralığında ise ismi geçen noktalara ek olarak *sağ chelion*, *sağ endocanthion*, *alt dudak tepe* ve *üst dudak dip* noktaları %100 başarı tespit oranına ulaşmıştır.

1.0 mm hassasiyet aralığında %0 başarı tespit oranı ile en az başarı ile işaretlenen noktalar *sol frontotemporale*, *sağ frontotemporale*, *nasion*, *sol zygion* ve *sağ zygion* noktaları olmuştur. 1.5 mm hassasiyet aralığında %0 başarı tespit oranı ile en az başarı ile işaretlenen noktalar *sağ frontotemporale* ve *nasion* noktaları olmuştur. 2.0 mm hassasiyet aralığında da %0 başarı tespit oranı ile *sağ frontotemporale noktası* en az başarı ile işaretlenen nokta olmuştur. 2.5 mm hassasiyet aralığında %1.67 başarı tespit oranı ile *nasion* ve *sağ zygion noktaları* en az başarı ile işaretlenen noktalar olmuştur. 3.0 mm hassasiyet aralığında %3.33 başarı tespit oranı ile, 4.0 mm hassasiyet aralığında ise %6.67 başarı tespit oranı ile en az başarı ile işaretlenen nokta *nasion* noktası olmuştur.

İkinci araştırmacının etiketlemesinde tüm noktalara ait ortalama radyal hata değeri, ortalama standart sapma değeri ve başarı tespit oranı ise Tablo 4.6'da sunulmuştur.

Tablo 4.6. İkinci araştırmacı etiketlemesine ait ORH, SS Ve BTO değerleri.

Referans Noktaları	ORH (mm)	SS (mm)	BTO (%)					
			1.0 mm	1.5 mm	2.0 mm	2.5 mm	3.0 mm	4.0 mm
Sol Ala Nasi	1.18	0.69	38.33	75.00	83.33	93.33	100.0	100.0
Sağ Ala Nasi	0.92	0.55	56.67	88.33	95.00	98.33	100.0	100.0
Sol Chelion	1.15	0.70	48.33	66.67	86.67	96.67	100.0	100.0
Sağ Chelion	1.06	0.57	46.67	85.00	93.33	96.67	98.33	100.0
Cubid's Bow	0.71	0.41	80.00	93.33	98.33	100.0	100.0	100.0
Sol Endocanthion	1.42	3.56	53.33	83.33	98.33	98.33	98.33	98.33
Sağ Endocanthion	0.81	0.53	75.00	91.67	96.67	98.33	98.33	100.0
Sol Exocanthion	3.50	11.32	21.67	48.33	70.00	78.33	86.67	93.33
Sağ Exocanthion	2.80	10.36	38.33	60.00	73.33	86.67	88.33	96.67
Dış Kornea	0.63	0.35	83.33	98.33	100.0	100.0	100.0	100.0
İç Kornea	0.68	0.27	88.33	100.0	100.0	100.0	100.0	100.0
Sol Frontotemporale	5.36	12.12	0.00	8.33	21.67	33.33	43.33	55.00
Sağ Frontotemporale	8.88	11.22	0.00	0.00	0.00	3.33	8.33	18.33
Glabella	2.41	1.51	18.33	31.67	46.67	56.67	73.33	85.00
Sol Gonion	5.10	3.95	5.00	13.33	28.33	38.33	43.33	51.67
Sağ Gonion	5.52	4.09	8.33	11.67	20.00	28.33	36.67	41.67
Alt Dudak Dip	1.62	0.95	28.33	48.33	68.33	83.33	93.33	96.67
Alt Dudak Tepe	1.62	0.85	26.67	48.33	70.00	86.67	91.67	100.0
Sol Mentale	4.19	6.43	13.33	23.33	31.67	40.00	50.00	66.67
Sağ Mentale	5.59	6.57	5.00	11.67	20.00	21.67	26.67	40.00
Menton	2.33	2.87	21.67	41.67	58.33	70.00	88.33	93.33
Nasal Taban	1.15	0.47	38.33	73.33	100.0	100.0	100.0	100.0
Nasal Dorsum	4.39	2.94	8.33	21.67	30.00	40.00	41.67	48.33
Nasion	8.60	3.39	0.00	0.00	1.67	1.67	3.33	6.67
Sol Orbitale	4.35	2.27	5.00	8.33	15.00	26.67	33.33	46.67
Sağ Orbitale	4.45	2.28	3.33	6.67	15.00	21.67	28.33	48.33
Sol Kulak	5.87	4.71	8.33	20.00	26.67	31.67	38.33	48.33
Sağ Kulak	6.40	5.42	13.33	23.33	26.67	30.00	36.67	40.00
Pogonion	5.37	2.49	1.67	6.67	13.33	15.00	15.00	30.00
Pronasale	1.88	0.99	18.33	38.33	61.67	73.33	86.67	96.67
Sol Pupil	1.53	7.54	88.33	98.33	98.33	98.33	98.33	98.33
Sağ Pupil	1.48	7.62	88.33	96.67	98.33	98.33	98.33	98.33
Üst Dudak Sağ Tüberkül	1.63	1.77	43.33	61.67	76.67	86.67	90.00	96.67
Üst Dudak Sol Tüberkül	1.50	1.70	36.67	63.33	81.67	93.33	98.33	98.33
Üst Dudak Dip	1.24	0.70	43.33	75.00	86.67	95.00	98.33	100.0
Trichion	4.73	2.48	3.33	8.33	15.00	21.67	30.00	38.33
Vertex	5.24	3.47	6.67	10.00	16.67	26.67	38.33	43.33
Sol Zygion	6.10	2.67	0.00	5.00	8.33	10.00	13.33	23.33
Sağ Zygion	7.12	3.75	0.00	1.67	1.67	1.67	5.00	16.67

4.2. Araştırmacıların ve Derin Öğrenme Modeli Tahminlerinin Ortalama

Radyal Hata ve Standart Sapma Değerlerinin Karşılaştırılması

Gruplar arasındaki farkın karşılaştırılması amacıyla post-hoc istatistiğinden yararlanılmıştır. Varyansların eşit olması sebebiyle Sidak çoklu karşılaştırma yöntemi kullanılmıştır. Gruplara ait ortalama ve standart sapmalarının karşılaştırıldığı tek yönlü varyans analizi tablosu Tablo 4.7'de verilmiştir.

Tablo 4.7. Tek yönlü varyans analizi.

Referans Noktaları	Asıl Araştırmacı	İkinci Araştırmacı	DÖ Modeli
Sol Ala Nasi	0.42±1.33a	1.18±0.69b	1.04±0.82b
Sağ Ala Nasi	0.61±3.25	0.92±0.55	1.09±1.32
Sol Chelion	0.89±4.43	1.15±0.7	1.09±0.93
Sağ Chelion	0.66±1.96a	1.06±0.57ab	1.1±0.77b
Cubid's Bow	0.52±1.94	0.71±0.41	0.84±0.53
Sol Endocanthion	0.62±3.56	1.42±3.56	1.03±2.08
Sağ Endocanthion	0.64±3.46	0.81±0.53	1.01±1.32
Sol Exocanthion	0.73±1.45a	3.5±11.32b	1.1±1.75a
Sağ Exocanthion	0.93±1.56	2.8±10.36	1.04±1.56
Dış Kornea	0.32±1.28	0.63±0.35	0.79±2.28
İç Kornea	0.41±2.2	0.68±0.27	0.68±1.64
Sol Frontotemporale	3.15±10.8	5.36±12.12	2.68±4.49
Sağ Frontotemporale	2.75±7.96a	8.88±11.22b	2.87±2.1a
Glabella	1.16±6.52	2.41±1.51	1.33±1.54
Sol Gonion	5.1±15.67	5.1±3.95	3.13±4.8
Sağ Gonion	2.41±4.04a	5.52±4.09b	2.71±4.65a
Alt Dudak Dip	0.4±0.69a	1.62±0.95c	1.11±0.67b
Alt Dudak Tepe	0.75±2.87a	1.62±0.85c	0.88±1.09b
Sol Mentale	2.01±4.61a	4.19±6.43b	2.86±2.11ab
Sağ Mentale	4.01±4.61a	5.59±6.57b	3.38±2.24a
Menton	1.39±7.66	2.33±2.87	1.49±1.91
Nasal Taban	0.75±4.45	1.15±0.47	0.92±1.23
Nasal Dorsum	1.59±2.38a	4.39±2.94b	1.91±1.27a
Nasion	1.84±2.83a	8.6±3.39b	1.76±1.32a
Sol Orbitale	2.95±2.87a	4.35±2.27b	2.32±2.07a
Sağ Orbitale	2.38±2.67a	4.45±2.28b	1.91±1.77a
Sol Kulak	1.85±4.28a	5.87±4.71b	3.37±9a
Sağ Kulak	1.49±4.01a	6.4±5.42b	3.3±8.93a
Pogonion	1.57±2.45a	5.37±2.49b	1.89±1.18a
Pronasale	1.13±2.26a	1.88±0.99b	1.37±1.09a
Sol Pupil	0.73±4.5	1.53±7.54	0.64±0.78
Sağ Pupil	0.57±3.24	1.48±7.62	0.56±0.64
Üst Dudak Sağ	0.74±1.38a	1.63±1.77b	1.14±0.84a
Tüberkül			

Tablo 4.7. Tek yönlü varyans analizi (devamı).

Üst Dudak Sol Tüberkül	0.82±3.15	1.5±1.7	1.14±0.76
Üst Dudak Dip	1.19±9.1	1.24±0.7	0.81±0.51
Trichion	1.78±1.66a	4.73±2.48c	2.71±2.35b
Vertex	2.26±9.11a	5.24±3.47b	2.66±3.44a
Sol Zygion	4.22±4.25a	6.1±2.67c	3.12±2.43b
Sağ Zygion	3.02±5.1a	7.12±3.75b	2.58±1.69a

Ortalama ve standart sapmaları içeren tek yönlü varyans testi sonuçlarına göre aşağıdaki bulgular elde edilmiştir:

- "*Alt dudak dip*", "*alt dudak tepe*", "*trichion*" ve "*sol zygion*" noktalarının etiketlenmesinde üç grup arasında anlamlı bir farklılık tespit edilmiştir. (p<0.05)
- "*Sol exocanthion*", "*sağ frontotemporale*", "*sağ gonion*", "*sağ mentale*", "*nasal dorsum*", "*nasion*", "*sol orbitale*", "*sağ orbitale*", "*sol kulak*", "*sağ kulak*", "*pogonion*", "*pronasale*", "*üst dudak tüberkül*", "*vertex*" ve "*sağ zygion*" noktalarının etiketlenmesinde, asıl araştırmacı etiketlemesi ile DÖ modeli tahminleri arasında anlamlı bir farklılık gözlenmezken, ikinci araştırmacının etiketlemesi ve diğer iki grup arasında anlamlı bir farklılık olduğu görülmüştür. (p<0.05)
- "*Sol mentale*" noktasının etiketlenmesinde, asıl araştırmacı ve ikinci araştırmacı etiketlemeleri arasında anlamlı bir farklılık gözlenirken, DÖ modelinin tahminleri diğer iki gruptan anlamlı bir farklılık sergilememiştir. (p<0.05)
- "*Sağ chelion*" noktasının etiketlenmesinde, asıl araştırmacı etiketlemesi ile DÖ modeli tahminleri arasında anlamlı bir farklılık gözlenmiştir; ancak ikinci araştırmacının etiketlemesi ile diğer iki grup arasında anlamlı bir farklılık gözlenmemiştir. (p<0.05)

- "*Sol ala nasi*" noktasının etiketlenmesinde, DÖ modeli tahminleri ile ikinci araştırmacı etiketlemesi arasında anlamlı bir farklılık gözlenmemiştir. Ancak, asıl araştırmacının etiketlemesi diğer iki gruptan anlamlı şekilde farklılık göstermiştir. ($p<0.05$)
- "*Sağ ala nasi*", "*sol chelion*", "*cubid's bow*", "*sol endocanthion*", "*sağ endocanthion*", "*sağ exocanthion*", "*dış kornea*", "*iç kornea*", "*sol frontotemporale*", "*glabella*", "*sol gonion*", "*menton*", "*nasal taban*", "*sol pupil*", "*sağ pupil*", "*üst dudak sol tüberkül*" ve "*üst dudak dip*" noktalarının etiketlenmesinde üç grup arasında anlamlı bir farklılık gözlenmemiştir. ($p<0.05$)

Asıl araştırmacının etiketlemesindeki tüm referans noktalarına ilişkin ortalama radyal hata (1.55 ± 4.2 mm) ile DÖ modeli tahminlerine ilişkin ortalama radyal hata (1.82 ± 2.55 mm) arasında anlamlı bir farklılık bulunmazken, ikinci araştırmacının etiketlemesine ilişkin ortalama radyal hata (3.35 ± 4.5 mm) bu iki gruptan istatistiksel olarak anlamlı farklılık arz etmektedir.

4.3. Araştırmacıların ve Derin Öğrenme Modelinin Başarı Tespit Oranlarının Karşılaştırılması

Asıl araştırmacı etiketlemesi, ikinci araştırmacı etiketlemesi ve geliştirilen DÖ modeli tahminlerinin 2.0 mm hassasiyet aralığında gösterdiği başarı tespit oranları karşılaştırılmıştır. Bu üç grubun çarpıklık ve basıklık değerleri incelendiğinde, örneklemin Tabachnick'e göre (Tabachnick ve ark., 2013) normal dağılım gösterdiği görülmüştür. Üç gruba ait başarı tespit oranları arasında pozitif yönde bir korelasyon bulunmuştur ($p<0.05$). Korelasyon değerlerine ait veriler Tablo 4.8'de verilmiştir. Asıl araştırmacı etiketlemesi ve ikinci araştırmacı etiketlemesi arasında (0.88), asıl araştırmacı etiketlemesi ve DÖ modeli tahminleri arasında (0.912) ve ikinci araştırmacı etiketlemesi

ve DÖ tahminleri arasındaki (0.916) korelasyon değerleri 0.71-0.99 aralığındadır. Bu aralıktaki değerler Tavşancıl (Tavşancıl, 2010) ve Köklü'ye (Köklü ve ark., 2007) göre çok güçlü düzeyde ve pozitif yöndedir.

Tablo 4.8. Korelasyon değerleri.

Gruplar		Korelasyon Değeri
DÖ Modeli Tahminleri	- Asıl Araştırmacı Etiketlemesi	0.912
DÖ Modeli Tahminleri	- İkinci Araştırmacı Etiketlemesi	0.916
Asıl Araştırmacı Etiketlemesi	- İkinci Araştırmacı Etiketlemesi	0.88

Üç gruba ait 2.0 mm hassasiyet aralığındaki başarı tespit oranları güvenilirlik yönünden incelenmiştir. Cronbach's alpha değeri 0.929 olarak bulunmuştur.

5. TARTIŞMA

Bu çalışmanın amacı, yüzdeki anatomik referans noktalarını yapay zeka yardımıyla belirlemektir. Bu hedef doğrultusunda, cephe yüz istirahat fotoğrafları arşivden seçilmiş ve yapay zeka modelinin eğitimi için etiketlenmiştir. Yapay zeka modelinin eğitimi için derin öğrenmeye başvurulmuştur. DÖ, son zamanlarda görüntü tanıma alanında birçok yarışma kazanmış ve başarılı sonuçlar elde etmiş bir YZ türüdür (Pak ve Kim, 2017). Çalışmamızda, görüntü tanıma alanında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nın (IBÖGTY) 2015 yılı kazananı Resnet DÖ mimarisi (Russakovsky ve ark., 2015) kullanılmıştır. Görüntü tanımada derin rezidüel (artık) öğrenme ismiyle tanınan Resnet mimarisi, artık öğrenme bloklarından oluşur (He ve ark., 2015). Artık öğrenme bloklarında, derin ağ içerisindeki bir katmanın çıktısı, başka bir katmanın girdisini oluşturur. Bu şekilde, bir önceki katmanın çıktıları bir sonraki katmana aktararak ağın yeni ve farklı bir özelliği öğrenmesi sağlanır. ResNet mimarisi, bu ağ yapısıyla %3.57'lik bir hata oranı elde ederek yarışmanın galibi olmuştur. Böylelikle, elde edilen %3.57 hata oranıyla, ilk kez insan algısı aşılabilmektedir (Alom ve ark., 2019). Ayrıca, artık ağların katkısıyla ResNet mimarisi, LeNet mimarisindeki 22 katman yerine 152 katman derinliğinde bir eğitim kapasitesine ulaşarak 8 kat büyüme sağlamış ve düşük karmaşıklığa ulaşmıştır (Elhassouny ve Smarandache, 2019). Ağın katman sayısı arttıkça, doğruluğun doygunluğa ulaştığı ve belli bir noktadan sonra ise kötüleştiği gözlemlenmiştir. Bu durum, kaybolan gradyan problemi adı verilen eğitim aşamasının daha zor hale geldiği ve veri miktarının önemli ölçüde artması gerektiği duruma sebep olmaktadır. ResNet mimarisinde, bahsedilen sorunun çözümü için bağlantı atlama (skip connection) özelliği geliştirilmiştir (Ajit ve ark., 2020). ResNet mimarisi, daha derin ağlar içermesi, yüksek ağ performansı sağlaması ve artan ağ derinliği ile ilişkili yan etkileri çözmesi gibi avantajlara sahiptir (Li ve ark., 2021). ResNet mimarisinin dezavantajları

ise, eğitim aşamasının uzun sürmesi, küçük veri kümelerinde düşük performans göstermesi ve yüksek performanslı bilgisayarlar gerektirmesidir (Jianfei ve Changming, 2020).

Ortodontide DÖ yöntemini kullanan çalışmaların çoğu, sefalometrik filmlerden otomatik referans noktası tespit etme üzerine yoğunlaşmıştır. Son yıllarda, ESA gibi DÖ algoritmalarının, hem iki boyutlu hem de üç boyutlu radyografilerde referans noktalarını tespit etmede diğer YZ algoritmalarından daha iyi performans gösterdiği görülmüştür (Cao ve ark., 2022). IEEE Uluslararası Biyomedikal Görüntüleme Sempozyumu (ISBI) tarafından ortak bir veri kümesi sağlanarak lateral sefalometrik filmlerden otomatik referans noktası tespiti için YZ modelleri geliştirilmiştir. En başarılı modellerin 2.0 mm, 3.0 mm ve 4.0 mm hassasiyet aralığındaki başarı tespit oranları listelenmiştir. İbragimove ve ark. (2014) tarafından geliştirilen YZ modelinin sırasıyla %70.21, %81.58 ve %88.16; Linder ve ark. (2015) tarafından geliştirilen YZ modelinin sırasıyla %74.84, %84.79 ve %89.95; Arik ve ark. (2017) tarafından geliştirilen YZ modelinin sırasıyla %75.58, %84.68 ve %88.05 başarı tespit oranına ulaştığı görülmüştür. Kim ve ark. (2020) tarafından geliştirilen ve diğer YZ modellerine göre daha başarılı olduğu görülen YZ modelinin ise 2.0 mm, 3.0 mm ve 4.0 mm hassasiyet aralığında başarı tespit oranı sırasıyla %84.53, %93.21 ve %96.79 bulunmuştur (Juneja ve ark., 2021). Çalışmamız yöntem açısından yukarıdaki çalışmalara benzese de çalışmamızın veri kümesini sefalometrik radyografiler değil istirahat halinde alınmış cephe yüz fotoğrafları oluşturmaktadır. Bu fotoğraflar standardize olmayıp milimetrik ölçüme olanak sağlayan bir cetvel içermemektedir. Bu sorunun aşılması için referans ölçüm oluşturmak amacıyla çalışmaya kornea noktaları eklenerek yeni bir yöntem de geliştirilmiştir.

Kornea çapı (white to white distance), limbustan limbusa yatay ve dikey yönde kumpas veya çeşitli topografi cihazlarıyla ölçülmektedir. Çalışmamızda da korneanın

yatay yöndeki çapını hesaplamak için iki referans noktası oluşturulmuştur. Korneanın yatay çapı birçok çalışmada ölçülmüştür. Dinç ve ark. (2010), kırk katılımcının yer aldığı bir çalışmada IOLMaster ve OrbscanIIz cihazlarını kullanarak 80 gözde kornea yatay çapını ölçmüşlerdir. Çalışma sonuçlarına göre, IOLMaster cihazı kornea yatay çapını ortalama 11.87 ± 0.35 mm, OrbscanIIz cihazı ise 11.65 ± 0.32 mm olarak ölçmüştür (Dinc ve ark., 2010). Kafkas ırkında yapılan ve ölçüm yapılan göz sayısı 743 olduğu bir çalışmada, kornea çaplarının ortalama genişliği 11.71 ± 0.42 mm olarak bulunmuştur (Rufer ve ark., 2005). Bu çalışmada ölçülen göz sayısı benzer çalışmalardan daha yüksektir (Mashige, 2013). Bu sebeple çalışmamızın *dış* ve *iç kornea* noktaları arasındaki toplam pixel uzunluğu 11.71 mm olarak kabul edilmiş ve milimetrik dönüşüm yapılmıştır.

Yüz incelemeleri, doğrudan veya dolaylı yöntemlerle gerçekleştirilebilir. Doğrudan yöntemlerde elde edilen ölçümlerin doğruluk oranının, yüksek olduğu bildirilmektedir. Antropometrik ölçümler, yüz deformiteleri ve konjenital anomalilerin tanı ve tedavi planlaması için başvuru olan doğrudan yöntemlerden biridir. Antropometri, saçın kapladığı bölgenin ölçümünde, başın özel olarak konumlandırıldığı durumlarda yapılan ölçümlerde ve altta yatan kemik yapısının ölçülmesinde dolaylı yöntemlere göre avantajlar sağlamaktadır (Farkas ve Deutsch, 1996).

Görüntüleme tekniklerinin gelişmesi, görüntülerin saklanabilmesi, indirekt çalışmanın konforu ve ölçümlerin tekrarlanabilirliği, dolaylı yöntemlerin daha fazla tercih edilmesine yol açmıştır. Dolaylı yöntemlerden biri olan fotoğrafik yöntem, fotoğrafların elde edilmesinin pratik olması avantajı sebebiyle sıklıkla kullanılmaktadır. Bu yöntemin standartlaştırılmış bir teknik gerektirdiği de çeşitli araştırmacılar tarafından dile getirilmiştir (DiBernardo ve ark., 1998; Ettorre ve ark., 2006; Zarem, 1984). Standartlaştırılmış bir teknikte çekilen bir fotoğrafta baş pozisyonu, kamera pozisyonu ve

birey ile kamera arasındaki mesafe standart hale getirilmelidir. Yüz oranlarının doğru bir şekilde değerlendirilmesi için, fotoğraf çekimi sırasında kişi doğal baş pozisyonunda olmalıdır (Moorrees ve Kean, 1958). Doğal baş pozisyonu 1-2 derece aralığında tekrarlanabilir olup (Cooke, 1990), kişinin kendi göz hizasında bulunan uzaktaki bir nesneye odaklanırken başının aldığı pozisyonudur. İnterpupillar çizgi ve kamera yatay düzleme paralel olmalıdır. Gözün dış kantusu kulağın üst çizgisiyle aynı düzlemde olmalıdır. İdeal olarak, kameranın bir tripod üzerine sabitlenmesi ve her fotoğraf çekiminin aynı uzaklıktan yapılması önerilmektedir (Claman ve ark., 1990).

Yüz fotoğraflarında oluşan perspektif bozulmasını önlenmesi için kullanılacak lensin odak uzaklığının doğru seçilmesi önemlidir. İnsan optik sisteminin odak uzaklığı 90 mm'lik bir merceğe (lense) eşdeğer olduğu bildirilmiştir. Bu fizyolojik yakınlığı yakalamak ve perspektif bozulmasını önlemek için, bir yüzün fotoğrafı yaklaşık 90 mm'lik bir lens ile çekilmelidir (Scholz, 1998). Çalışmamızda model eğitime, 100 mm odak uzaklığına sahip bir objektif kullanılarak elde edilmiş yüz fotoğrafları ile başlanmıştır. Model performansı ara değerlendirmesinde, DÖ modelini eğitmek için çok daha fazla sayıda fotoğrafa ihtiyaç olduğu fark edilmiştir. Daha sonra arşiv fotoğrafları model eğitime dahil edilince model performansının arttığı gözlenmiştir. Böylelikle model eğitimi için çoğunlukla arşiv fotoğrafları kullanılmıştır. Çalışmamızda kullanılan arşiv fotoğraflarının 29-88 mm aralığında odak uzaklığına sahip bir Canon (Canon Inc, Tokyo, Japonya) lens ile çekildiği görülmüştür. Model eğitiminde fizyolojik ve sabit odak uzaklığına sahip lens kullanımının etkili olup olmadığı konusunda bir çalışmaya rastlanmamıştır.

Fotoğraflar, üç boyutlu yumuşak dokuların iki boyutlu gösterimlerini yapmaktadır. Fotoğrafik yöntemde bu diferansiyel bozulmadan etkilenme söz konusudur. Fotoğraflar standartlaştırılmış bir teknikle elde edilse bile, iki nokta arasındaki mesafenin

doğrusal olarak ölçülmesi, ölçümlerin tamamen güvenilir olmasını engellemektedir (Farkas ve Deutsch, 1996). Bununla bağlantılı olarak, fotoğrafik yöntemin güvenilirliğini değerlendirmek için, fotoğrafik yöntem sonuçlarını diğer yüz ölçüm yöntemlerinin sonuçlarıyla karşılaştırmak yerine, fotoğrafik yöntem ölçümlerini tekrarlayarak ölçümlerin sonuçlarını karşılaştırmının daha uygun olacağı söylenebilir (Payne, 2013).

Fotogrametrik fasiyal yumuşak doku ölçümlerinin doğruluğu ve güvenilirliği, Farkas ve arkadaşlarının (1980) dikkatini çekmiştir. Antropometrik referans noktaları, yüz ve kafa derisi üzerine mürekkep kullanılarak işaretlenmiştir. Ölçümler doğrudan veya çalışmaya katılan bireylerin fotoğrafları aracılığıyla yapılmıştır. Farkas ve ark. (1980), 104 antropometrik yüz ölçümünden 62'sini frontal ve sagittal fotoğraflara uyarlamışlardır. Bu 62 fotogrametrik ölçümden 26'sı güvenilir olarak kabul edilmiştir. Bu ölçümlerin güvenilir kabul edilmesi için kriter, doğrudan ölçümlerden en fazla 1 mm veya 2 derece farklı olmalarıdır. En güvenilir ölçümler dudak ve ağız bölgesinde yapılmıştır. Ölçüm için kullanılan referans noktaları objektif ile aynı hizada olduğundan bu bölgedeki ölçümlerin doğruluğu yüksek bulunmuştur (Farkas ve ark., 1980). Geliştirdiğimiz DÖ modeli yukarıdaki çalışmaya benzer şekilde dudak ve burunda bulunan referans noktalarını düşük ortalama radyal hata ile tahmin etmiştir.

Shaner ve ark. (1998) yaptıkları çalışmada, kumpasla ve fotogrametrik yöntemle yapılan ölçümleri karşılaştırmışlardır. Çalışmaya göre, fotogrametrik ölçümlerin ortalamaları ve standart sapmaları oldukça büyüktür ve veriler arasında sistematik bir fark oluşturmaktadır. Bu araştırmacılar ayrıca yüzdeki referans noktalarını kalemle işaretledikten sonra ölçüm yapmanın güvenilirliği artıracığını bildirmişlerdir (Shaner ve ark., 1998).

Fotosefalometri, ortognatik cerrahi hastalarının yumuşak dokularını değerlendirmek için fotoğrafların ve sefalometrik görüntülerin üst üste bindirildiği bir

yöntemdir (Hohi ve ark., 1978). Phillips ve ark (1984), fotosefalometri yöntemiyle 12 ortodontik hastanın hem cepheden hem de lateralden alınmış fotoğraflarında projeksiyon ve referans noktası belirleme hatalarını araştırmışlardır. Çalışma verileri, 12 fotoğrafın üçer tane asetat çakıştırmasından oluşmaktadır. Cephe fotoğraflarında 47'si anatomik referans noktası olmak üzere toplamda 124 nokta işaretlenmiştir. Cephe fotoğraflarındaki referans noktalarının %57'sinin ortalama hata değerinin 2.0 mm'den küçük veya eşit olduğu bulunmuştur. İlgili çalışmada *sağ pupil* ve *sağ superior naris* noktaları en güvenilir noktalar olarak belirlenmiştir. Sırasıyla bu *noktaları pronasale, sol neck point, sağ exocanthion, endocanthion sağ, sağ lateral naris* ve *nasal inferius* noktaları izlemektedir. En düşük güvenilirliğe sahip noktalar, sırasıyla *sol prominence of cheek, sağ malar, sağ cheek inferius, sol cheek inferius, sağ prominence of cheek, sol inferior palpebrion, sağ malar, sol chin, sağ gonion, prominence of chin, sağ inferior palpebrion, sol gonion, inferior labial sulcus, menton* ve *sağ chin* noktalarıdır. Yüz referans noktaları belirlenirken, hatanın büyüklüğünün noktadan noktaya değiştiği ve çoğu referans noktası için kavisli yüzeylerde büyük hatalar olduğu görülmüştür (Phillips ve ark., 1984). Phillips ve ark. (1984) çalışmasında, tüm noktaların %57'sinin 2.0 mm'den daha az bir hata değeriyle bulunduğu belirtilirken, geliştirilen DÖ modeli tüm noktaların %66.6'sını 2.0 mm'den daha az bir hata değeri ile tahmin etmiştir. Phillips ve ark. (1984)'nın çalışmasındakine benzer olarak DÖ modeli *pupil* noktalarını yüksek başarı ile tespit etmiştir. Yine Phillips ve ark. (1984) çalışmasıyla benzer olarak *gonion, mentale, kulak, zygion* gibi noktalar DÖ modeli tarafından yüksek hata oranı ile tahmin edilmiştir.

Ghoddousi ve ark. (2007) yaptıkları çalışmada manuel antropometri, üç boyutlu stereofotogrametri ve fotogrametri yöntemleriyle yapılan ölçümlerin doğruluğunu değerlendirmeyi amaçlamıştır. Çalışmaya katılan altı gönüllünün yüzündeki 14 referans noktasından ölçümler yapılmış ve elde edilen ölçümler diğerleriyle karşılaştırılmıştır. Her

üç ölçüm yönteminin de iyi bir tekrarlanabilirliğe sahip olduğu ve fotogrametrik ölçümlerin manuel ölçümlerden daha yüksek bir değişkenliğe sahip olduğu rapor edilmiştir (Ghoddousi ve ark., 2007).

Rousseau ve Retrouvey (2022) yüz dikey boyutunu otomatik olarak hesaplamak için yaptıkları bir çalışmada *gnation*, *interlabial temas noktası*, *subnazale* ve *nasion* noktalarını dijital yöntemlerle tespit etmişlerdir. (Rousseau ve Retrouvey, 2022) Bu tespitler hem manuel seçimle hem de bir makine öğrenmesi modeliyle gerçekleştirilmiştir. Bu noktaların belirlenmesinin ardından alt yüz yüksekliği, maksiller ve mandibular yumuşak doku ölçümleri yapılmıştır. Manuel yöntemle ve makine öğrenimi modeliyle yapılan ölçümler arasındaki ortalama fark alt yüksekliği için 2.92 mm, maksiller yumuşak doku ölçümleri için 0.75 mm ve mandibular yumuşak doku ölçümleri için 2.18 mm bulunmuştur. İlgili çalışma tez çalışmamızla fotoğraf üzerinden nokta tespit edilmesi yönüyle benzerlik göstermektedir. Bununla birlikte geliştirdiğimiz DÖ modeli ilgili çalışmadaki tüm referans noktalarını 2.0 mm altında hata ile tahmin etmiştir. Ancak noktalar arasındaki uzunluk ölçümü çalışmamız kapsamında yer almamaktadır. Bunun yanında Rousseau ve Retrouvey (2022) yaptıkları çalışmada 45 yüz fotoğrafı kullanılırken bu tez çalışmasında 2872 yüz fotoğrafı kullanılmıştır.

Rao ve ark. (2019) yaptıkları bir çalışmada, YOLO isimli DÖ algoritmasını kullanarak iki boyutlu yüz fotoğraflarında referans noktası belirlenmesi ve analizinde yöntemin etkinliğini ve doğruluğunu araştırmışlardır (Rao ve ark., 2019). Çalışmada 22 yüz görüntüsünde 418 referans noktası (her bir fotoğraf için 19 referans noktası) ve 220 referans noktası ölçümü (her bir fotoğraf için 10 ölçüm) kullanılmıştır. Model eğitiminde 10.117 görüntü kullanılmıştır. Tüm ölçümlerin %97'sinin 0-5 mm aralığında değişen hata ile ölçüm yaptığı bulunmuştur. Geliştirdiğimiz DÖ modelinde ise noktalar arası mesafe

ölçülmemiş olup tüm noktalarda 0.56 mm ile 3.38 mm aralığında fark olduğu tespit edilmiştir.

Bu tezde geliştirilen DÖ modelinin tahminleri incelendiğinde, x ve y koordinat düzlemindeki sapmayı belirten genel ortalama radyal hata değerinin 1.82 ± 2.55 mm olduğu görülmüştür. Modelin tahminlerinde, ortalama radyal hata değeri 1.82 mm'nin altında olup daha başarılı bir şekilde tahmin edildiğini söyleyeceğimiz noktalar ise şunlardır: *Sol ala nasi, sağ ala nasi, sol chelion, sağ chelion, cubid's bow, sol endocanthion, sağ endocanthion, sol exocanthion, sağ exocanthion, dış kornea, iç kornea, glabella, alt dudak dip, alt dudak tepe, menton, nasal taban, nasion, pronasale, sol pupil, sağ pupil, üst dudak sağ tüberkül, üst dudak sol tüberkül ve üst dudak dip* noktaları. Ortalama radyal hata değerinin 1.82 mm'nin üzerinde olup daha az başarı ile tahmin edildiğini söyleyeceğimiz noktalar ise şunlardır: *Sol frontotemporale, sağ frontotemporale, sol gonion, sağ gonion, sol mentale, sağ mentale, nasal dorsum, sol orbitale, sağ orbitale, sağ kulak, sol kulak, pogonion, trichion, vertex, sol zygion ve sağ zygion* noktaları.

Ortalama radyal hata değeri arttıkça 2.0 mm, 3.0 mm ve 4.0 mm hassasiyet aralıklarında başarı tespit oranı değerlerinin düştüğü görülmektedir. Ortalama radyal hata değeri genel ortalamanın altında olan noktalardan *nasion* noktası tahmininin 1.76 ± 1.32 mm ile en yüksek radyal hata değerine sahip nokta olduğu ve bu noktanın 2.0 mm hassasiyet aralığında %68.39'luk bir başarı tespit oranına ulaştığı görülmüştür. Bu nokta tahminini, 1.49 ± 1.91 mm radyal hata değeri ile 2.0 mm hassasiyet aralığında %78.76 başarı tespit oranına ulaşan *menton* noktası tahmini takip ederken, *pronasale* noktası tahmini ise 1.37 ± 1.09 mm radyal hata değeri ile 2.0 mm hassasiyet aralığında %80.44 başarı tespit oranı göstermiştir. Radyal hata değerleri genel ortalamanın altında kalan diğer noktaların ise 2.0 mm hassasiyet aralığında %84.5'in üzerinde bir başarı tespit

oranına ulaştığı görülmüştür. Ortalama radyal hata değeri arttıkça, başarı tespit oranlarının azalması oldukça muhtemeldir. Düşük ortalama radyal hata değerlerine sahip olan noktalar daha yüksek başarı ile tahmin edilen noktalar olarak kabul edilir. Yukarıda bahsedilen noktaların aksine, daha az başarı ile tahmin edilen yani yüksek ortalama radyal hata değerlerine sahip noktalara bakacak olursak; radyal hata değeri 3.38 ± 2.24 mm olan *sağ mentale* noktası, 2.0 mm hassasiyet aralığında %30.31 başarı tespit oranı ile en yüksek radyal hata değerini göstermiştir. Bu noktayı 3.37 ± 9.0 mm radyal hata değeri ile *sol kulak* noktası takip etmiş ve ilgili nokta tahmininin 2.0 mm hassasiyet aralığında %52.72 başarı tespit oranına sahip olduğu görülmüştür.

Araştırmacı aynı verileri yeniden etiketlemesi sonrası, genel radyal ortalama hata değeri 1.55 ± 4.2 mm olarak hesaplanmıştır. Yeniden etiketleme sonuçlarına göre, aynı araştırmacının DÖ modeli tahminlerinden daha düşük bir hata ile etiketleme yaptığı görülmüştür. Bununla birlikte, bazı noktalar için DÖ modelinin tahminlerinin ortalama radyal hata değerleri, araştırmacının ikinci etiketlemesinden daha düşük bulunmuştur. Bu noktalar ise şunlardır: *sol frontotemporale*, *sol gonion*, *sağ mentale*, *nasion*, *sol orbitale*, *sağ orbitale*, *üst dudak dip*, *sol zygion*, *sağ zygion*, *sol pupil* ve *sağ pupil*. *Pupil* noktalarında, araştırmacının ikinci etiketlemesi ile DÖ modeli tahminleri oldukça yakın radyal hata değerleri göstermiştir. Araştırmacının ikinci etiketlemesi ve geliştirilen YZ modeli tahminlerinin başarı tespit oranları karşılaştırıldığında ise, tüm referans noktaları için 1.0 mm hassasiyet aralığında araştırmacının ikinci kez etiketlemesinin daha başarılı olduğu görülmektedir. Ancak, 1.5 mm hassasiyet aralığında, *sol exocanthion* (%81.48) ve *sağ exocanthion* (%83.55) noktalarında DÖ modeli tahminlerinin daha başarılı olduğu görülmektedir. DÖ modeli tahminlerinin 2.0 mm hassasiyet aralığında, *sol exocanthion*, *sağ exocanthion*, *nasion*, *sol orbitale*, *sağ pupil* ve *sol zygion* noktalarında daha başarılı olduğu görülmüştür. DÖ modeli tahminlerinin 2.5 mm hassasiyet aralığında, *cubid's bow*,

sol exocanthion, sađ exocanthion, alt dudak tepe, nasion, sol orbitale, sađ orbitale, pronasale, sol pupil, sađ pupil ve *sol zygion* noktalarında daha başarılı olduđu görölmüştür. DÖ modeli tahminlerinin 3.0 mm hassasiyet aralığında, *cubid's bow, sađ endocanthion, sol exocanthion, sađ exocanthion, glabella, sađ gonion, alt dudak tepe, nasal dorsum, nasion, sol orbitale, sađ orbitale, pogonion, pronasale, sol pupil, sađ pupil, sol zygion* ve *sađ zygion* noktalarında daha başarılı olduđu görölmüştür. DÖ modeli tahminlerinin 4.0 mm hassasiyet aralığında, *sol ala nasi, sađ ala nasi, sol chelion, sađ chelion, cubid's bow, sol endocanthion, sađ endocanthion, sol exocanthion, sađ exocanthion, glabella, sađ gonion, alt dudak tepe, sađ mentale, nasal taban, nasal dorsum, nasion, sol orbitale, sađ orbitale, pogonion, pronasale, sol pupil, sađ pupil, üst dudak sađ tüberkül, üst dudak sol tüberkül, sol zygion* ve *sađ zygion* noktalarında yine daha başarılı olduđu görölmüştür.

İkinci araştırmacının etiketlemesinin genel ortalama radyal hata değeri 3.35 ± 3.50 mm'dir. İkinci araştırmacı ve asıl araştırmacının etiketlemesi karşılaştırıldığında ikinci araştırmacının ortalama radyal hata değelerinin daha yüksek olduđu görölmektedir. Bu durum genel olarak başarı tespit oranlarında da görölmektedir. Bu durumun muhtemel nedenleri arasında, ikinci araştırmacının noktaları subjektif olarak farklı yorumlayıp konumlandırması sayılabilir. Ayrıca, ikinci araştırmacının etiketleme yaptığı fotoğraf sayısının az olması da söylenebilir. Çünkü yaklaşık üç bin fotoğrafı etiketleyen asıl araştırmacı, başlangıçta etiketlediđi fotoğraflara baktığında noktaların konumunu değıştirme ihtiyacı hissetmiştir.

İkinci araştırmacının etiketlemesinde asıl araştırmacı etiketlemesiyle benzer olarak, düşük ortalama radyal hata değeri ve yüksek başarı tespit oranı ile işaretlediđi noktalar aşğıdaki gibidir: *Sol ala nasi, sađ ala nasi, sol chelion, sađ chelion, cubid's bow, sol endocanthion, sađ endocanthion, sol exocanthion, sađ exocanthion, dış kornea,*

iç kornea, alt dudak dip, alt dudak tepe, nasal taban, pronasale, sol pupil, sağ pupil, üst dudak sağ tüberkül, üst dudak sol tüberkül ve üst dudak dip. Bu 20 referans noktasının genel ortalama radyal hata değeri 1.43 ± 2.60 mm'dir ve 2.0 mm hassasiyet aralığında başarı tespit oranı %86.83'tür.

DÖ modelinin, ikinci araştırmacı etiketlemesinden daha düşük ortalama radyal hata değeri ve yüksek başarı tespit oranlarıyla (yüksek çoğunlukla) tahmin ettiği noktalar aşağıdaki gibidir: *Sağ ala nasi, sağ chelion, cubid's bow, sağ endocanthion ve dış kornea. İç kornea* noktasının ortalama radyal hata değeri ise ikinci araştırmacı ve DÖ modeli tahminlerinde eşit çıkmıştır. Bu noktalara ilaveten, ikinci araştırmacı etiketlemesi ve DÖ tahminleri *nasal taban ve sol pupil* noktaları benzer başarı tespit oranları göstermiştir.

İlk araştırmacı etiketlemesi, ikinci araştırmacı etiketlemesi ve DÖ modeli tahminleri ortalama radyal hata değeri açısından karşılaştırıldığında, çoğunlukla asıl araştırmacı etiketlemesinin en düşük hata değerlerine ulaştığı görülmektedir. Diğer yandan DÖ modeli tahminleri, *sol frontotemporale, sol gonion, sağ mentale, nasion, sol orbitale, sağ orbitale, sol pupil, sağ pupil, üst dudak dip, sol zygion ve sağ zygion* noktalarında daha düşük ortalama radyal hata değerlerine ulaşmıştır. *Frontotemporale, gonion, mentale, orbitale ve zygion* noktaları derin öğrenme modeli tarafından daha düşük başarı ile tahmin edilen noktalar olarak göze çarpsa da burada etiketleyicilere karşı üstünlük sağlamıştır. Bu durum, derin öğrenme tahminlerinin belirli bir hata aralığının altında yoğunlaştığını göstermektedir. Başka bir deyişle, sapma çok fazla artmamakta ve nokta tahminleri belirli bir bölgede yoğunlaşmaktadır. İkinci araştırmacı etiketlemesi ise, ortalama radyal hata değerleri yönünden asıl araştırmacı etiketlemesi ve DÖ modeli tahminlerinden daha düşük bir radyal hata değerine ulaşamamıştır.

Asıl araştırmacı etiketlemesi, ikinci araştırmacı etiketlemesi ve DÖ modeli tahminleri, başarı tespit oranları açısından karşılaştırıldığında, asıl araştırmacı

etiketlemesinin daha yüksek başarı tespit oranlarına ulaştığı görülmüştür. Bununla birlikte, DÖ modeli tahminlerinin 2.0 mm hassasiyet aralığında *sol exocanthion*, *sağ exocanthion*, *nasion*, *sol orbitale*, *sağ orbitale*, *sağ pupil* ve *sol zygion* noktalarında daha yüksek başarı tespit oranlarına ulaştığı görülmüştür. Bu noktalar için başarı tespit oranları derin öğrenme ve asıl araştırmacı için oldukça yakın olduğundan, derinlemesine bir yorum yapmak zordur.

Ek olarak karşılaştırılan üç grubun da 2.0 mm hassasiyet aralığında %90 ve üzeri başarı tespit oranına ulaştığı noktalar şunlardır: *sağ ala nasi*, *cubid's bow*, *sol endocanthion*, *sağ endocanthion*, *dış kornea*, *iç kornea*, *nasal taban*, *sol pupil* ve *sağ pupil*. İlgili noktalar genel olarak yorumlandığında, göz ve çevresiyle ilgili referans noktalarının yüksek başarıyla işaretlendiği görülmektedir. DÖ modelinin *pupil* noktalarını en yüksek başarı ile tahmin ettiği görülmüştür. Bunun muhtemel nedenlerinden biri *pupil* noktasının dairesel olan korneanın geometrik merkezinde yer alması olabilir. Bir başka olası neden ise fotoğraf çekimlerinde gözün lensle aynı hizada olması ve bu nedenle fotoğraflarda en net çıkan bölge olması olabilir.

Asıl araştırmacının ikinci etiketlemesinde DÖ modelinin yüksek başarı ile tahmin ettiği noktaları daha az sapma ile işaretlediği görülmüştür. Ayrıca asıl araştırmacının ikinci etiketlemesinde DÖ modelinin daha az başarı ile tahmin ettiği noktaları, ilk etiketlemeye kıyasla daha büyük hata değerleriyle etiketlemiş olduğu görülmüştür. Bunların yanı sıra, DÖ modeli tahminlerinin 2.0-4.0 mm hassasiyet aralığında başarı tespit oranlarının istikrarlı bir şekilde arttığı görülmüştür. Hassasiyet aralığı arttıkça noktaların başarı oranlarının artması oldukça doğaldır. Asıl araştırmacı ile DÖ öğrenme modeli arasındaki bu benzerliğin, model eğitiminin ana araştırmacı tarafından yapılmış olmasının bir etkisi olduğu ifade edilebilir.

Çalışmamızda, asıl araştırmacı etiketlemesi, ikincil araştırmacı etiketlemesi ve DÖ modeli tahminlerinin genel ortalama radyal hata değerleri arasında istatistiksel olarak anlamlı bir fark olduğu gözlemlenmiş, bu farkın kaynağının ise ikinci araştırmacı etiketlemesinden kaynaklandığı görülmektedir. Bu durum, ikinci araştırmacının etiketlemesinin derin öğrenme modeline ve asıl araştırmacıya göre daha sübjektif olması ve model eğitimi için etiketlemenin asıl araştırmacı tarafından yapılmış olmasıyla açıklanabilir.

Ayrıca, çalışmada milimetrik ölçümlerin yapılabilmesi için tercih edilen "*dış kornea*" ve "*iç kornea*" noktaları, ortalama radyal hata değerleri yönünden karşılaştırıldığında üç farklı grup arasında anlamlı bir fark gözlenmemiştir.

6. SONUÇ VE ÖNERİLER

Geliştirilen DÖ modelinin yüz incelemeleri için gerekli olan referans noktalarını tahmin etmede etkili olduğu görülmüştür. Referans noktaları, yüz üzerinde konumlandıkları bölgeye bağlı olarak değişen başarı oranlarıyla tespit edilmiştir. DÖ modelinin düşük hata ve yüksek başarı oranı ile tahmin ettiği referans noktaları, dokuların kesişim bölgesinde, bir dokuya ait kıvrımın üzerinde veya renk tonunda değişimin olduğu bölgede yer alması göze çarpmaktadır. DÖ modelinin daha az başarı ile tahmin ettiği noktaların yüzün orta hattından uzak yüz dış hattında ya da yüz dış hattına yakın noktalar olması dikkat çekicidir.

DÖ modelinin yüksek başarı ile tahmin ettiği noktalar: *sol ala nasi, sağ ala nasi, sol chelion, sağ chelion, cubid's bow, sol endocanthion, sağ endocanthion, sol exocanthion, sağ exocanthion, dış kornea, iç kornea, glabella, alt dudak dip, alt dudak tepe, menton, nasal taban, pronasale, sol pupil, sağ pupil, üst dudak sağ tüberkül, üst dudak sol tüberkül* ve *üst dudak dip* noktalarıdır.

DÖ modeli tahminlerinin asıl araştırmacı etiketlemesinden daha başarılı olduğu noktalar ise şunlardır: *cubid's bow, dış kornea, iç kornea, alt dudak tepe, nasal taban, sol pupil, sağ pupil, üst dudak dip*.

DÖ modelinin an az başarı ile tahmin ettiği noktalar ise şunlardır: *sol frontotemporale, sağ frontotemporale, sol gonion, sağ gonion, sol mentale, sağ mentale, nasion, sol orbitale, sağ orbitale, sol kulak, sağ kulak, pogonion, trichion, vertex, sol zygion* ve *sağ zygion*.

Sonuç olarak, DÖ modelinin yüz incelemeleri için kullanılan referans noktalarını tahmin etmede etkili ve başarılı olduğu görülmektedir. Geliştirilen DÖ modelinin başarı tespit oranı 2.0 mm hassasiyet aralığında %73.17 ve 4.0 mm aralığında %91.98 bulunmuştur.

Başarılı olduğu düşünülen referans noktalarının yüz incelemelerinde kullanılabilmesi için yeterli düzeyde doğruluğa sahip olduğu söylenebilir. Bu söylemi DÖ modeli tarafından daha az başarı ile tahmin edilen referans noktalarının ikinci araştırmacı etiketlemesinden daha yüksek başarı ile tahmin etmesi de desteklemektedir. Bu bağlamda geliştirilen DÖ modelinin yüz incelemeleri için kabul edilebilir tahminler yaptığı sonucuna varılabilir.

Bu tez çalışmasının limitasyonları ise:

- Fotoğraf üzerinden referans noktalarının tespitinde ve değerlendirilmesinde standart bir yöntemin olmaması
- Referans noktalarının işaretlenmesinin subjektif olması,
- Model eğitiminin tek kişi etiketlemesi ile gerçekleştirilmesi,
- Modelin geliştirilmesinde kullanılan yüz fotoğraflarının tek merkezden elde edilmiş olması,
- Bulgular, araştırmacının orijinal etiketlemesi ile diğer etiketlemeler arasındaki farkın ortalaması olduğundan, araştırmacı içi ve araştırmacılar arası güvenilirlik testlerinin kullanılamamasıdır.

Elde ettiğimiz DÖ modelinin klinikte rutin kullanıma uygun olabileceğini düşünmekteyiz. Bunula birlikte tüm yüz referans noktaları için çok düşük bir radyal hata oranı ve çok yüksek bir başarı tespit oranı elde edilmelidir. Bu hedefe ulaşmak için çok büyük veri kümelerinin kullanılması, çok sayıda etiketleyicinin olması ve modellerin çok daha gelişkin mimarilerle desteklenmesi gerektiği söylenebilir. Bu hedefe ulaşmada model eğitiminin, veri kümesini renk veya milimetrik kalibrasyona sahip fotoğraflarla (üç boyutlu yüz görüntüleri ve lidar kameralarla elde edilmiş fotoğraflar gibi) gerçekleştirilmesi de katkı sağlayabilir.

KAYNAKLAR

- Abdalla-Aslan, R., Yeshua, T., Kabla, D., Leichter, I., and Nadler, C. (2020). An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surgery, Oral Medicine, Oral Pathology And Oral Radiology*, 130(5), 593–602.
- Abràmoff, M. D., Lavin, P. T., Birch, M., Shah, N., and Folk, J. C. (2018). Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *NPJ Digital Medicine*, 1, 39.
- Ajit, A., Acharya, K., and Samanta, A. (2020). A Review of Convolutional Neural Networks. *2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)*, 1-5.
- Alom M.Z., Taha T.M., Yakopcic C., Westberg S., Sidike P., Nasrin M.S., Hasan M., Van Essen B.C., Awwal A.A.S. and Asari V.K. (2019). A state-of-the-art survey on deep learning theory and architectures. *Electronics*, 8(3):292
- Aminoshariae, A., Kulild, J., and Nagendrababu, V. (2021). Artificial intelligence in endodontics: current applications and future directions. *Journal of Endodontics*, 47(9), 1352–1357.
- Arnett, G. W., and Bergman, R. T. (1993). Facial keys to orthodontic diagnosis and treatment planning. Part I. *American Journal of Orthodontics and Dentofacial Orthopedics*, 103(4), 299-312.
- Bas, B., Ozgonenel, O., Ozden, B., Bekcioglu, B., Bulut, E., and Kurt, M. (2012). Use of artificial neural network in differentiation of subgroups of temporomandibular internal derangements: a preliminary study. *J Oral Maxillofac Surg*, 70(1), 51-59.
- Bernini, J. M., Kellenberger, C. J., Eichenberger, M., Eliades, T., Papageorgiou, S. N., and Patcas, R. (2020). Quantitative analysis of facial asymmetry based on three-

- dimensional photography: a valuable indicator for asymmetrical temporomandibular joint affection in juvenile idiopathic arthritis patients? *Pediatric Rheumatology Online Journal*, 18(1), 10.
- Broadbent, B. H. (1931). A new x-ray technique and its application to orthodontia. *The Angle Orthodontist*, 1(2), 45-66.
- Brooks, R. A., Breazeal, C., Marjanović, M., Scassellati, B., and Williamson, M. M. (1999). The cog project: building a humanoid robot. *Computation for Metaphors, Analogy, and Agents, Berlin, Heidelberg*, 52-87.
- Burke, P. H., and Beard, F. H. (1967). Stereophotogrammetry of the face. A preliminary investigation into the accuracy of a simplified system evolved for contour mapping by photography. *American Journal of Orthodontics*, 53(10), 769-782.
- Burstone, C. J. (1959). Integumental contour and extension patterns. *The Angle Orthodontist*, 29(2), 93-104.
- Camci, H., and Salmanpour, F. (2022). Estimating the size of unerupted teeth: Moyers vs deep learning. *American Journal of Orthodontics and Dentofacial Orthopedics*, 161(3), 451-456.
- Campbell, M., Hoane, A. J., and Hsu, F.-h. (2002). Deep blue. *Artificial Intelligence*, 134(1), 57-83.
- Cao, L., He, H., and Hua, F. (2022). Deep learning algorithms have high accuracy for automated landmark detection on 2d lateral cephalograms. *Journal of Evidence-Based Dental Practice*, 22(4), 101798.
- Cha, J. Y., Yoon, H. I., Yeo, I. S., Huh, K. H., and Han, J. S. (2021). Peri-implant bone loss measurement using a region-based convolutional neural network on dental periapical radiographs. *Journal of Clinical Medicine*, 10(5), 1009.

- Chang, H. J., Lee, S. J., Yong, T. H., Shin, N. Y., Jang, B. G., Kim, J. E., Huh, K. H., Lee, S. S., Heo, M. S., Choi, S. C., Kim, T. I., and Yi, W. J. (2020). Deep learning hybrid method to automatically diagnose periodontal bone loss and stage periodontitis. *Scientific Reports*, 10(1), 7531.
- Chartrand, G., Cheng, P. M., Vorontsov, E., Drozdal, M., Turcotte, S., Pal, C. J., Kadoury, S., and Tang, A. (2017). Deep learning: a primer for radiologists. *Radiographics*, 37(7), 2113-2131.
- Chen, S.-L., Zhou, H.-S., Chen, T.-Y., Lee, T.-H., Chen, C.-A., Lin, T.-L., Lin, N.-H., Wang, L.-H., Lin, S.-Y., Chiang, W.-Y., Abu, P. A. R., and Lin, M.-Y. (2020). Dental shade matching method based on hue, saturation, value color model with machine learning and fuzzy decision. *Sensors and Materials*, 32(10), 3185-3207.
- Choi, H. I., Jung, S. K., Baek, S. H., Lim, W. H., Ahn, S. J., Yang, I. H., and Kim, T. W. (2019). Artificial intelligent model with neural network machine learning for the diagnosis of orthognathic surgery. *Journal of Craniofacial Surgery*, 30(7), 1986-1989.
- Claman, L., Patton, D., and Rashid, R. (1990). Standardized portrait photography for dental patients. *American Journal of Orthodontics and Dentofacial Orthopedics*, 98(3), 197-205.
- Cooke, M. S. (1990). Five-year reproducibility of natural head posture: a longitudinal study. *American Journal of Orthodontics and Dentofacial Orthopedics*, 97(6), 489-494.
- DiBernardo, B. E., Adams, R. L., Krause, J., Fiorillo, M. A., and Gheradini, G. (1998). Photographic standards in plastic surgery. *Plastic and Reconstructive Surgery*, 102(2), 559-568.

- Dinc, U. A., Oncel, B., Gorgun, E., Yenerel, M. N., and Alimgil, L. (2010). Assessment and comparison of anterior chamber dimensions using various imaging techniques. *Ophthalmic Surgery, Lasers and Imaging Retina*, 41(1), 115-122.
- Do, S., Song, K. D., and Chung, J. W. (2020). Basics of deep learning: a radiologist's guide to understanding published radiology articles on deep learning. *Korean Journal of Radiology*, 21(1), 33-41.
- Doğan, F. and Türkoğlu I (2018). *He comparison of leaf classification performance of deep learning algorithms. Sakarya University Journal of Computer and Information Sciences*, 1, 10-21.
- Ekert, T., Krois, J., Meinhold, L., Elhennawy, K., Emara, R., Golla, T., and Schwendicke, F. (2019). Deep learning for the radiographic detection of apical lesions. *Journal of Endodontics*, 45(7), 917-922 e915.
- Elhassouny, A., and Smarandache, F. (2019). Trends in deep convolutional neural Networks architectures: a review. 2019 International Conference of Computer Science and Renewable Energies (ICCSRE), 1-8.
- Elmas, Ç. (2021). *Yapay zeka uygulamaları*. Seçkin Yayıncılık, Ankara.
- Erickson, B. J., Korfiatis, P., Akkus, Z., and Kline, T. L. (2017). Machine learning for medical imaging. *Radiographics*, 37(2), 505.
- Ettorre, G., Weber, M., Schaaf, H., Lowry, J. C., Mommaerts, M. Y., and Howaldt, H. P. (2006). tandards for digital photography in cranio-maxillo-facial surgery - Part I: Basic views and guidelines. *Journal of Cranio-Maxillofacial Surgery*, 34(2), 65-73.
- Farkas, L., and Deutsch, C. (1996). Anthropometric determination of craniofacial morphology. *American Journal of Medical Genetics*, 65, 1-4.

- Farkas, L. G., Bryson, W., and Klotz, J. (1980). Is photogrammetry of the face reliable? *Plastic and Reconstructive Surgery*, 66(3), 346-355.
- Farkas, L. G., Katic, M. J., Forrest, C. R., Alt, K. W., Bagic, I., Baltadjiev, G., Cunha, E., Cvicelova, M., Davies, S., Erasmus, I., Gillett-Netting, R., Hajnis, K., Kemkes-Grottenthaler, A., Khomyakova, I., Kumi, A., Kgamphe, J. S., Kayo-daigo, N., Le, T., Malinowski, A., . . . Yahia, E. (2005). International anthropometric study of facial morphology in various ethnic groups/races. *Journal of Craniofacial Surgery*, 16(4), 615-646.
- Ferrario, V. F., Sforza, C., Poggio, C. E., and Serrao, G. (1996). Facial three-dimensional morphometry. *American Journal of Orthodontics and Dentofacial Orthopedics*, 109(1), 86-93.
- Finlay, L. M. (1980). Craniometry and cephalometry: a history prior to the advent of radiography. *The Angle Orthodontist*, 50(4), 312-321.
- Forsyth, D. B., and Davis, D. N. (1996). Assessment of an automated cephalometric analysis system. *European Journal of Orthodontics*, 18(5), 471–478.
- Fu, L., Feng, Y., Majeed, Y., Zhang, X., Zhang, J., Karkee, M., and Zhang, Q. (2018). Kiwifruit detection in field images using Faster R-CNN with ZFNet. *IFAC-PapersOnLine*, 51(17), 45-50.
- Fukuda, M., Inamoto, K., Shibata, N., Arijji, Y., Yanashita, Y., Kutsuna, S., Nakata, K., Katsumata, A., Fujita, H., and Arijji, E. (2020). Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiology*, 36(4), 337-343.
- Galeso, M. (2017). *Apple Siri for Mac: An Easy Guide to the Best Features*. First Rank Publishing, India.

- Gavan, J. A., Washburn, S. L., and Lewis, P. H. (1952). Photography: an anthropometric tool. *American Journal of Physical Anthropology*, 10(3), 331-353.
- Gazilerli, Ü. (1999). *Ortodonti Yönünden Fotoğrafçılık*. Atatürk Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı, Erzurum.
- Ghoddousi, H., Edler, R., Haers, P., Wertheim, D., and Greenhill, D. (2007). Comparison of three methods of facial measurement. *International Journal of Oral and Maxillofacial Surgery*, 36(3), 250-258.
- Gil, S. M., Kim, I., Cho, J. H., Hong, M., Kim, M., Kim, S. J., Kim, Y. J., Kim, Y. H., Lim, S. H., Sung, S. J., Baek, S. H., Kim, N., and Kang, K. H. (2022). Accuracy of auto-identification of the posteroanterior cephalometric landmarks using cascade convolution neural network algorithm and cephalometric images of different quality from nationwide multiple centers. *American Journal of Orthodontics and Dentofacial Orthopedics*, 161(4), e361-e371.
- Girshick, R. B. (2015). Fast R-CNN. *2015 IEEE International Conference on Computer Vision (ICCV)*, 1440-1448.
- Graber, L. W., Vig, K. W., Huang, G. J., and Fleming, P. (2022). *Orthodontics-e-book: current principles and techniques*. Elsevier Health Sciences, Philadelphia, USA.
- Gürsakal, N. (2017). Makine öğrenmesi ve derin öğrenme. *Dora Basım Yayın Dağıtım, Bursa*.
- Hagg, U., and Taranger, J. (1982). Maturation indicators and the pubertal growth spurt. *American Journal of Orthodontics*, 82(4), 299-309.
- Hajeer, M. Y., Millett, D. T., Ayoub, A. F., and Siebert, J. P. (2004). Current products and practices. *Journal of Orthodontics*, 31(1), 62-70.
- Hamzaçebi, C. (2021). *Matlab Uygulamalı Yapay Sinir Ağları*. Seçkin Yayıncılık, Ankara.

- Harorli, A. (2014). Ağız, Diş ve Çene Radyolojisi. Nobel Tıp Kitabevleri, İstanbul.
- He, K., Zhang, X., Ren, S., and Sun, J. (2015). Deep Residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.
- Hellman, M. (1939). Some facial features and their orthodontic implication. *American Journal of Orthodontics and Oral Surgery*, 25(10), 927-951.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *ArXiv, abs/1207.0580*.
- Hohi, T. H., Wolford, L. M., Epker, B. N., and Fonseca, F. J. (1978). Craniofacial ostetomies: a photocephalometric technique for the prediction and evaluation of tissue changes. *The Angle Orthodontist*, 48(2), 114-125.
- Hrdlička, A. (1920). *Anthropometry*. *American Journal of Physical Anthropology*, VolumIII(1), 147-173.
- Hung, M., Voss, M. W., Rosales, M. N., Li, W., Su, W., Xu, J., Bounsanga, J., Ruiz-Negron, B., Lauren, E., and Licari, F. W. (2019). Application of machine learning for diagnostic prediction of root caries. *Gerodontology*, 36(4), 395-404.
- Javed, S., Zakirulla, M., Baig, R. U., Asif, S. M., and Meer, A. B. (2020). Development of artificial neural network model for prediction of post-streptococcus mutans in dental caries. *Computer Methods and Programs in Biomedicine*, 186, 105198.
- Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., Guadarrama, S., and Darrell, T. (2014). Caffe: Convolutional architecture for fast feature embedding. *Proceedings of the 22nd ACM international conference on Multimedia*, 675-678.

- Jianfei, C., and Changming, Z. (2020). Research on image recognition based on improved ResNet. 2020 IEEE 6th International Conference on Computer and Communications (ICCC), 1422-1426.
- Jin, H., Liao, S., and Shao, L. (2020). Pixel-in-pixel net: Towards efficient facial landmark detection in the wild. *International Journal of Computer Vision*, 129, 3174-3194.
- Juneja, M., Garg, P., Kaur, R., Manocha, P., Prateek, Batra, S., Singh, P., Singh, S., and Jindal, P. (2021). A review on cephalometric landmark detection techniques. *Biomedical Signal Processing and Control*, 66, 102486.
- Jung, S. K., and Kim, T. W. (2016). New approach for the diagnosis of extractions with neural network machine learning. *American Journal of Orthodontics and Dentofacial Orthopedics*, 149(1), 127-133.
- Kamil, Ö. (1991). Kinantropometri ve spor. *Beden Eğitimi ve Spor Araştırmaları Dergisi*, 2(5), 36-39.
- Karatas, O. H., and Toy, E. (2014). Three-dimensional imaging techniques: A literature review. *European Journal of Dentistry*, 8(1), 132-140.
- Khalid, M. A., Zulfiqar, K., Bashir, U., Shaheen, A., Iqbal, R., Rizwan, Z., Rizwan, G., and Fraz, M. M. (2022). CEPHA29: Automatic Cephalometric Landmark Detection Challenge 2023, arXiv:2212.04808.
- Khanagar, S. B., Al-Ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., Sarode, S. C., and Bhandi, S. (2021). Developments, application, and performance of artificial intelligence in dentistry - A systematic review. *Journal of Dental Sciences*, 16(1), 508-522.
- Kim, B. S., Yeom, H. G., Lee, J. H., Shin, W. S., Yun, J. P., Jeong, S. H., Kang, J. H., Kim, S. W., and Kim, B. C. (2021). Deep Learning-Based Prediction of

- Paresthesia after Third Molar Extraction: A Preliminary Study. *Diagnostics* (Basel), 11(9).
- Kim, D. W., Kim, H., Nam, W., Kim, H. J., and Cha, I. H. (2018). Machine learning to predict the occurrence of bisphosphonate-related osteonecrosis of the jaw associated with dental extraction: A preliminary report. *Bone*, 116, 207-214.
- Kok, H., Acilar, A. M., and Izgi, M. S. (2019). Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Progress in Orthodontics*, 20(1), 41.
- Kositbowornchai, S., Plermkamon, S., and Tangkosol, T. (2013). Performance of an artificial neural network for vertical root fracture detection: an ex vivo study. *Dental Traumatology*, 29(2), 151-155.
- Köklü, N., Büyüköztürk, Ş., and Çokluk-Bökeoğlu, Ö. (2007). *Sosyal Bilimler İçin İstatistik*. Pegem Akademi Yayıncılık, Ankara.
- Krois, J., Ekert, T., Meinhold, L., Golla, T., Kharbot, B., Wittemeier, A., Dorfer, C., and Schwendicke, F. (2019). Deep learning for the radiographic detection of periodontal bone loss. *Scientific Reports*, 9(1), 8495.
- Kubat, M. (1999). Neural networks: a comprehensive foundation by Simon Haykin, Macmillan, 1994, ISBN 0-02-352781-7. *The Knowledge Engineering Review*, 13(4), 409-412.
- Kunz, F., Stellzig-Eisenhauer, A., Zeman, F., and Boldt, J. (2020). Artificial intelligence in orthodontics : Evaluation of a fully automated cephalometric analysis using a customized convolutional neural network. *Journal of Orofacial Orthopedics*, 81(1), 52-68.

- Kurt Bayrakdar, S., Orhan, K., Bayrakdar, I. S., Bilgir, E., Ezhov, M., Gusarev, M., and Shumilov, E. (2021). A deep learning approach for dental implant planning in cone-beam computed tomography images. *BMC Medical Imaging*, 21(1), 86.
- Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Lee, C. T., Kabir, T., Nelson, J., Sheng, S., Meng, H. W., Van Dyke, T. E., Walji, M. F., Jiang, X., and Shams, S. (2022). Use of the deep learning approach to measure alveolar bone level. *Journal of Clinical Periodontology*, 49(3), 260-269.
- Lee, J. H., Kim, D. H., Jeong, S. N., and Choi, S. H. (2018a). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of Dentistry*, 77, 106-111.
- Lee, J. H., Kim, D. H., Jeong, S. N., and Choi, S. H. (2018b). Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *Journal of Periodontal and Implant Science*, 48(2), 114-123.
- Lee, K. S., Jung, S. K., Ryu, J. J., Shin, S. W., and Choi, J. (2020). Evaluation of transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs. *Journal of Clinical Medicine*, 9(2), 392.
- Li, Q., Yang, Y., Guo, Y., Li, W., Liu, Y., Liu, H., and Kang, Y. (2021). Performance evaluation of deep learning classification network for image features. *IEEE Access*, 9, 9318-9333.
- Liu, Z., Liu, J., Zhou, Z., Zhang, Q., Wu, H., Zhai, G., and Han, J. (2021). Differential diagnosis of ameloblastoma and odontogenic keratocyst by machine learning of panoramic radiographs. *International Journal of Computer Assisted Radiology and Surgery*, 16, 415-422.

- Lu, C.-H., Ko, E. W.-C., and Liu, L. (2009). Improving the video imaging prediction of postsurgical facial profiles with an artificial neural network. *Journal of Dental Sciences*, 4(3), 118-129.
- Mashige, K. P. (2013). A review of corneal diameter, curvature and thickness values and influencing factors. *African Vision and Eye Health*, 72(4), 185-194.
- McCarthy, J. (2004). What is artificial intelligence? URL: <https://www-formal.stanford.edu/jmc/whatisai/>
- McCarthy, J., Minsky, M. L., Rochester, N., and Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-12.
- Meneghini, F., and Biondi, P. (2012). Clinical facial analysis: elements, principles, and techniques. *Springer Science and Business Media*, Berlin, Germany.
- Mohammad-Rahimi, H., Nadimi, M., Rohban, M. H., Shamsoddin, E., Lee, V. Y., and Motamedian, S. R. (2021). Machine learning and orthodontics, current trends and the future opportunities: A scoping review. *American Journal of Orthodontics and Dentofacial Orthopedics*, 160(2), 170-192 e174.
- Moorrees, C. F. A., and Kean, M. R. (1958). Natural head position, a basic consideration in the interpretation of cephalometric radiographs. *American Journal of Physical Anthropology*, 16(2), 213-234.
- Mupparapu, M. (2005). Radiation protection guidelines for the practicing orthodontist. *American Journal of Orthodontics and Dentofacial Orthopedics*, 128(2), 168-172.
- Murata, M., Arij, Y., Ohashi, Y., Kawai, T., Fukuda, M., Funakoshi, T., Kise, Y., Nozawa, M., Katsumata, A., Fujita, H., and Arij, E. (2019). Deep-learning

- classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral Radiology*, 35(3), 301-307.
- Nabiyev, V. (2021). *Yapay Zeka (Artificial Intelligence)*, Seçkin Yayıncılık, Ankara.
- Naini, F. B. (2011). Facial aesthetics: concepts and clinical diagnosis. John Wiley and Sons.
- Nilsson, N. J. (1984). Shakey the robot. SRI International, USA.
- Nilsson, N. J. (2018). Yapay Zeka Geçmişi ve Geleceği. Boğaziçi Üniversitesi Yayınevi, İstanbul.
- O'Regan, G. (2016). *Introduction to the History of Computing: A Computing History Primer*. Springer International Publishing, New York City, 143-149.
- Orhan, K., Bayrakdar, I. S., Ezhov, M., Kravtsov, A., and Ozyurek, T. (2020). Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *International Endodontic Journal*, 53(5), 680-689.
- Pak, M., and Kim, S. (2017). A review of deep learning in image recognition. 2017 4th International Conference on Computer Applications and Information Processing Technology (CAIPT), 1-3.
- Park, J. H., Hwang, H. W., Moon, J. H., Yu, Y., Kim, H., Her, S. B., Srinivasan, G., Aljanabi, M. N. A., Donatelli, R. E., and Lee, S. J. (2019). Automated identification of cephalometric landmarks: Part 1-Comparisons between the latest deep-learning methods YOLOV3 and SSD. *The Angle Orthodontist*, 89(6), 903-909.
- Patcas, R., Bernini, D. A. J., Volokitin, A., Agustsson, E., Rothe, R., and Timofte, R. (2019). Applying artificial intelligence to assess the impact of orthognathic treatment on facial attractiveness and estimated age. *International Journal of Oral and Maxillofacial Surgery*, 48(1), 77-83.

- Pauwels, R., Brasil, D. M., Yamasaki, M. C., Jacobs, R., Bosmans, H., Freitas, D. Q., and Haiter-Neto, F. (2021). Artificial intelligence for detection of periapical lesions on intraoral radiographs: Comparison between convolutional neural networks and human observers. *Oral Surgery, Oral Medicine, Oral Pathology And Oral Radiology*, 131(5), 610-616.
- Payne, M. G. (2013). *The reliability of facial soft tissue landmarks with photogrammetry*. A Thesis for the Degree of Master of Science. Marquette University, Milwaukee, WI.
- Pethani, F. (2021). Promises and perils of artificial intelligence in dentistry. *Australian Dental Journal*, 66(2), 124-135.
- Phillips, C., Greer, J., Vig, P., and Matteson, S. (1984). Photocephalometry: errors of projection and landmark location. *American Journal Of Orthodontics*, 86(3), 233-243.
- Pospelov, D. A. (1990). Yapay Zeka Modeller ve Yöntemler. *Kitap II, Radio i Svyaz*, Moskova, p-304.
- Proffit, W. R., Fields, H. W., Larson, B. and Sarver, D. M., 2018. Contemporary orthodontics-e-book. Elsevier Health Sciences, 735 p, Philadelphia, USA.
- Raith, S., Vogel, E. P., Anees, N., Keul, C., Guth, J. F., Edelhoff, D., and Fischer, H. (2017). Artificial Neural Networks as a powerful numerical tool to classify specific features of a tooth based on 3D scan data. *Computers in Biology and Medicine*, 80, 65-76.
- Rakosi T. (1982). An atlas of cephalometric radiography. *Wolfe Medical Publications*, 54-58.

- Rao, G. K. L., Srinivasa, A. C., Iskandar, Y. H. P., and Mokhtar, N. (2019). Identification and analysis of photometric points on 2D facial images: a machine learning approach in orthodontics. *Health and Technology*, 9(5), 715-724.
- Ren, S., He, K., Girshick, R. B., and Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39, 1137-1149.
- Reyneke, J., and Ferretti, C. (2012). Clinical Assessment of the Face. *Seminars in Orthodontics*, 18, 172–186.
- Reyneke, J. P., Tsakiris, P., and Kienle, F. (1997). A simple classification for surgical treatment planning of maxillomandibular asymmetry. *British Journal of Oral and Maxillofacial Surgery*, 35(5), 349-351.
- Ricketts, R. M. (1961). Cephalometric analysis and synthesis. *The Angle Orthodontist*, 31(3), 141-156.
- Rousseau, M., and Retrouvey, J. M. (2022). Machine learning in orthodontics: Automated facial analysis of vertical dimension for increased precision and efficiency. *American Journal of Orthodontics and Dentofacial Orthopedics*, 161(3), 445-450.
- Rufer, F., Schroder, A., and Erb, C. (2005). White-to-white corneal diameter: normal values in healthy humans obtained with the Orbscan II topography system. *Cornea*, 24(3), 259-261.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., and Fei-Fei, L. (2015). Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3), 211-252.

- Russell Stuart, J., and Norvig, P. (2010). *Artificial intelligence: a modern approach*. Prentice Hall, 1132, New Jersey.
- Saghiri, M. A., Asgar, K., Boukani, K. K., Lotfi, M., Aghili, H., Delvarani, A., Karamifar, K., Saghiri, A. M., Mehrvarzfar, P., and Garcia-Godoy, F. (2012). A new approach for locating the minor apical foramen using an artificial neural network. *International Endodontic Journal*, 45(3), 257-265.
- Sarver, D. M., and Ackerman, J. L. (2000). Orthodontics about face: the re-emergence of the esthetic paradigm. *American Journal of Orthodontics and Dentofacial Orthopedics*, 117(5), 575-576.
- Scholz, R. P. (1998). Considerations in selecting a digital camera for orthodontic records. *American Journal of Orthodontics and Dentofacial Orthopedics*, 114(5), 603-605.
- Schwendicke, F., Chaurasia, A., Arsiwala, L., Lee, J. H., Elhennawy, K., Jost-Brinkmann, P. G., Demarco, F., and Krois, J. (2021). Deep learning for cephalometric landmark detection: systematic review and meta-analysis. *Clinical Oral Investigations*, 25(7), 4299-4309.
- Setzer, F. C., Shi, K. J., Zhang, Z., Yan, H., Yoon, H., Mupparapu, M., and Li, J. (2020). Artificial Intelligence for the Computer-aided Detection of Periapical Lesions in Cone-beam Computed Tomographic Images. *Journal of Endodontics*, 46(7), 987-993.
- Shaner, D. J., Bamforth, J. S., Peterson, A. E., and Beattie, O. B. (1998). Technical note: Different techniques, different results-a comparison of photogrammetric and caliper-derived measurements. *American Journal of Physical Anthropology: The Official Publication of the American Association of Physical Anthropologists*, 106(4), 547-552.

- Shi, S., Wang, Q., Xu, P., and Chu, X. (2016). Benchmarking state-of-the-art deep learning software tools. In 2016 7th International Conference on Cloud Computing and Big Data (CCBD), 99-104.
- Shigemi, S. (2019). ASIMO and Humanoid Robot Research at Honda. *Humanoid Robotics: A Reference*, 55-90.
- Stoner, M. M. (1955). A photometric analysis of the facial profile. *American Journal of Orthodontics*, 41, 453-469.
- Sukegawa, S., Yoshii, K., Hara, T., Matsuyama, T., Yamashita, K., Nakano, K., Takabatake, K., Kawai, H., Nagatsuka, H., and Furuki, Y. (2021). Multi-task deep learning model for classification of dental implant brand and treatment stage using dental panoramic radiograph images. *Biomolecules*, 11(6), 815.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition, 1-9.
- Tabachnick, B. G., Fidell, L. S., and Ullman, J. B. (2013). *Using multivariate statistics* (6), 497,516. Boston, MA: Pearson.
- Tan, M. S., Tan, J. W., Chang, S. W., Yap, H. J., Abdul Kareem, S., and Zain, R. B. (2016). A genetic programming approach to oral cancer prognosis. *PeerJ*, 4, e2482.
- Tavşancıl, E. (2010). *Tutumların Ölçülmesi Ve SPSS ile Veri Analizi*. Nobel Yayınları, Ankara.
- Thanathornwong, B. (2018). Bayesian-Based Decision Support System for Assessing the Needs for Orthodontic Treatment. *Healthcare Informatics Research*, 24(1), 22-28.

- Toğaçar, M., and Ergen, B. (2019). Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1), 109-121.
- Topsakal, K. G., and Korkmaz, Y. N. (2018). Ortodontide üç boyutlu görüntüleme sistemleri: Literatür derlemesi. *Selcuk Dental Journal*, 5(2), 186-193.
- Turing, A. M. (1956). Can a machine think. *The World of Mathematics*, 4, 2099-2123.
- Tuzoff, D. V., Tuzova, L. N., Bornstein, M. M., Krasnov, A. S., Kharchenko, M. A., Nikolenko, S. I., Sveshnikov, M. M., and Bednenko, G. B. (2019). Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology*, 48(4), 20180051.
- van Dijk, J., and Williams, P. (1990). The history of artificial intelligence. In *Expert Systems In Auditing*, 21-26.
- Veleminska, J., Pilny, A., Cepek, M., Kot'ova, M., and Kubelkova, R. (2013). Dental age estimation and different predictive ability of various tooth types in the Czech population: data mining methods. *Anthropologischer Anzeiger*, 70(3), 331-345.
- Vinayahalingam, S., Xi, T., Berge, S., Maal, T., and de Jong, G. (2019). Automated detection of third molars and mandibular nerve by deep learning. *Scientific Reports*, 9(1), 9007.
- Wang, C. W., Huang, C. T., Hsieh, M. C., Li, C. H., Chang, S. W., Li, W. C., Vandaele, R., Marée, R., Jodogne, S., Geurts, P., Chen, C., Zheng, G., Chu, C., Mirzaalian, H., Hamarneh, G., Vrtovec, T., and Ibragimov, B. (2015). Evaluation and comparison of anatomical landmark detection methods for cephalometric x-ray images: A grand challenge. *IEEE Transactions on Medical Imaging*, 34(9), 1890-1900.

- Weizenbaum, J. (1966). ELIZA-a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1), 36-45.
- Xie, X., Wang, L., and Wang, A. (2010). Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *The Angle Orthodontist*, 80(2), 262-266.
- Yang, L., and Shami, A. (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415, 295-316.
- Yasa, Y., Celik, O., Bayrakdar, I. S., Pekince, A., Orhan, K., Akarsu, S., Atasoy, S., Bilgir, E., Odabas, A., and Aslan, A. F. (2021). An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs. *Acta Odontologica Scandinavica*, 79(4), 275-281.
- Yılmaz, A. (2021). *Derin Öğrenme*. Kodlab Yayın Dağıtım Yazılım ve Eğitim Hizmetleri, İstanbul.
- Zarem, H. A. (1984). Standards of photography. *Plastic and Reconstructive Surgery*, 74(1), 137-146.
- Zhang, W., Li, J., Li, Z. B., and Li, Z. (2018). Predicting postoperative facial swelling following impacted mandibular third molars extraction by using artificial neural networks evaluation. *Scientific Reports*, 8(1), 12281.

EKLER

EK-1. ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

SAĞLIK BİLİMLERİ ENSTİTÜSÜ Graduate School of Health Sciences	
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU¹	
Öğrencinin Adı ve Soyadı	Mehmet Rıdvan DEMİR
Öğrencinin Numarası	
Ana Bilim Dalı	Ortodonti
Öğrencinin Kayıtlı Olduğu Program Türü	Doktora

Yukarıda bilgileri verilen tezin intihal tespit yazılımıyla (Turnitin) yapılan tarama sonucunda elde edilen benzerlik oranları aşağıdaki gibidir. Beyan edilen bilgilerin doğru olduğunu, aksi hâlde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

Bölümler	Benzerlik Oranı	Maksimum Benzerlik Oranları
I. Giriş	% 0	% 15
II. Genel Bilgiler	% 4	% 35
III. Materyal ve Metod	% 4	% 35
IV. Bulgular	% 6	% 15
V. Tartışma	% 1	% 20

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

¹ Bu form bilgisayar ortamında doldurulmalı, çıktısı imzalanıp Tez Savunma Jüri Öneri Formu'yla birlikte Ana Bilim Dalı Başkanlığı aracılığıyla ÖBYS üzerinden Enstitüye iletilmelidir.

EK-2. ETİK KURUL ONAY FORMU



T.C.
ATATÜRK ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ DEKANLIĞI
ETİK KURULU

01.06.2021

Sayı : 36

ORTODONTİ ANABİLİM DALI BAŞKANLIĞINA

31.05.2021 tarihi ve 01 sayılı yazınız ekinde gönderilen ve Doç. Dr. Ali KIKI'nin danışmanlığında Arş. Gör. Dt. M. Rıdvan DEMİR'in birlikte hazırladığı "*Derin Öğrenme Yönteminin Yüzün Fotoğrafik İncelenmesindeki Etkinliğinin Değerlendirilmesi*" başlıklı Doktora tezine ait etik kurul başvurusu kurulumuz tarafından incelenmiş olup, konu ile ilgili alınan karar ekte sunulmuştur.

Bilgilerinizi arz ve rica ederim.



T.C.
ATATÜRK ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ DEKANLIĞI
ETİK KURULU

Oturum Tarihi: 01/06/2021
Oturum Sayısı: 05/ 2021

KARAR

SORUMLU ARAŞTIRMACI	<i>Doç. Dr. Ali KIKI</i> <i>Arş. Gör. Dt. M. Rıdvan DEMİR</i>
Araştırmanın Açık Adı	<i>Derin Öğrenme Yönteminin Yüzün Fotoğrafik İncelenmesindeki Etkinliğinin Değerlendirilmesi</i>
Karar No	36.
Alınan Karar	Doç. Dr. Ali KIKI'nin danışmanlığında Arş. Gör. Dt. M. Rıdvan DEMİR'in birlikte hazırladığı " <i>Derin Öğrenme Yönteminin Yüzün Fotoğrafik İncelenmesindeki Etkinliğinin Değerlendirilmesi</i> " başlıklı Doktora tezi Sağlık Bakanlığı tarafından yayımlanan 19 Ağustos 2011 tarih ve 28030 sayılı "Klinik Araştırmalar Hakkındaki Yönetmelik" hükümlerine bağlı kalınarak yapılmak şartıyla; kabul edilmesinde bilimsel ve etik açıdan sakınca olmadığına mevcudun oybirliği ile karar verildi.

EK-3. DİĞER FORMLAR

Fotoğraf çekimi için rıza belgesi aşağıdadır.

ATATÜRK ÜNİVERSİTESİ DİŞ HEKİMLİĞİ FAKÜLTESİ ORTODONTİ ANABİLİM DALI
TIBBİ FOTOĞRAF İÇİN AYDINLATILMIŞ ONAM FORMU

Sizden izin aldıktan sonra diş çene ve yüz sistemindeki probleminizi değerlendirmek amacıyla çekilecek olan fotoğraflar; kişisel tıbbi kaydınıza eklenmek; diş hekimliği ve tıp fakültesi gibi sağlık hizmetlerine yönelik eğitim almakta olabilecek öğrencilerin eğitimi amacıyla kullanılabilir. Bu kayıtlar onayınızla bilimsel araştırmalarda da kullanılacaktır. Bu formda ayrıntılı olarak bazı diğer özel ve sınırlı kullanımlar için imza istenmektedir.

Kaydedilecek görüntülerin nerelerde ve hangi amaçlarla kullanılacağını hekiminiz size açıklayacak ve onayınızı isteyecektir.

Dijital makinelerle çekilecek olan görüntüler çekimden sonra size gösterilecek ve uygun bulursanız kullanılacaktır.

Elde edilen görüntüler güvenli bir ortamda saklanacak, yetkisiz kişilerin kullanımı engellenecek ve yasal zorunluluklar dışında, tıp dışı kişi görme olasılığına karşı **TANINMANIZI ÖNLEYECEK İŞLEMLER YAPILDIKTAN VE KİMLİK BİLGİLERİNİZ GİZLENDİKTEN SONRA**, kişisel haklarınıza zarar vermeyecek şekilde kullanılacaktır. Eğitim ve bilimsel amaçlı olarak kullanılmasını kabul etmezseniz bile, bu görüntüler diğer tüm tıbbi kayıtlarınız gibi standart ve yasal bir tıbbi kayıt olarak kullanılacaktır.

Çekilen görüntülere onay verseniz bile daha sonra vazgeçme hakkına sahipsiniz. Ancak kayıtlar bilimsel yayın amacıyla kullanıldıktan sonra onayınızı geri çekmeniz mümkün değildir.

Bu kayıtların kullanılması nedeniyle size herhangi bir ücret ödenmeyecektir.

Fotoğraf kayıtlarının alınmasında bir hemşirenin, yakınınızın veya arkadaşınızın yanınızda bulunmasını talep edebilirsiniz.

Bana verilen bilgiler doğrultusunda kendime/çocuğuma/yakınıma ait fotoğraf çekilmesini kabul ediyorum

Kişisel tıbbi kaydım olarak kullanılacak bu görüntü kayıtlarının aynı zamanda aşağıda onay verdiğim alanlarda kullanılabilir. (Lütfen kabul etmediğiniz alanların üstünü çiziniz.)

Dış hekimliği ve tıp fakültesi gibi sağlık öğrencileri ve diş hekimlerinin, tıp profesyonellerinin eğitiminde, Doktora ve uzmanlık tezi basılı metinlerinde, Uygun bilimsel dergilerde ve bilimsel kitaplarda basılı olarak, Ulusal ve uluslararası bilimsel toplantılarda, Bilimsel amaçlarla elektronik ortamlarda.

Yukarıda izin verdiğim alanlar dışında başka bir amaçla kullanılması gerektiğinde, benden tekrar izin isteneceği tarafıma bildirilmiştir.

Hastanın Adı/Soyadı	Hastanın Dosya Numarası	Telefon
Hastanın İmzası	Hasta Yakını/Vasisi/Velisi Adı soyadı ve İmzası	Hekimim Adı Soyadı ve İmzası
		Tarih

Bu form hasta dosyasında saklanacaktır.