T.C.

ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ

DİŞ HEKİMLİĞİ FAKÜLTESİ

KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN ELDE EDİLEN POSTEROANTERİOR SEFALOMETRİK (FRONTAL) GÖRÜNTÜLER ÜZERİNDE DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKA ALGORİTMALARIYLA SEFALOMETRİK NOKTALARIN TESPİTİ

Gizem Gözde ÖZŞAHİN

Ortodonti Anabilim Dalı

Uzmanlık Tezi

Tez Danışmanı

Dr. Öğr. Üyesi Mehmet UĞURLU

ESKİŞEHİR

2023

T.C.

ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ

DİŞ HEKİMLİĞİ FAKÜLTESİ

ORTODONTİ ANABİLİM DALI

KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN ELDE EDİLEN POSTEROANTERİOR SEFALOMETRİK (FRONTAL) GÖRÜNTÜLER ÜZERİNDE DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKA ALGORİTMALARIYLA SEFALOMETRİK NOKTALARIN TESPİTİ

Gizem Gözde ÖZŞAHİN

Tez Savunma Tarihi: 02.01.2023

Tez Danışmanı: Dr. Öğr. Üyesi Mehmet UĞURLU(Eskişehir Osmangazi Üniversitesi)

Jüri Üyesi: Doç. Dr. Ali KİKİ (Erzurum Atatürk Üniversitesi)

Jüri Üyesi: Dr. Öğr. Üyesi Hasan CAMCI (Afyon Sağlık Bilimleri Üniversitesi)

Onay

Bu çalışma yukarıdaki jüri tarafından Uzmanlık Tezi olarak kabul edilmiştir.

Prof. Dr. Batu Can YAMAN

Dekan

Uzmanlık Tezi

ESKİŞEHİR-2023

UZMANLIK TEZİ BEYANNAMESİ

Uzmanlık tezi olarak sunduğum "**KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN ELDE EDİLEN POSTEROANTERİOR SEFALOMETRİK (FRONTAL) GÖRÜNTÜLER ÜZERİNDE DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKA ALGORİTMALARIYLA SEFALOMETRİK NOKTALARIN TESPİTİ**" başlıklı araştırmayı danışmanım **Dr. Öğr. Üy. Mehmet UĞURLU**'nun rehberlik ve sorumluluğunda tamamladığımı; çalışma protokolü ve hazırlık süresince bilimsel araştırma ve etik kurallara uygun davrandığımı, verilerin tarafımdan toplandığını, örneklerin tarafımca hazırlandığını; deney, analiz ve görüntüleme işlemlerinin ilgili laboratuvar ve görüntüleme merkezinde tarafımca yapıldığını/yaptırıldığını, tez metnini hazırlarken kaynakçanın eksiksiz olarak gösterildiğini, tezin yazım kılavuzu kurallarına uygun olarak hazırlandığını ve belirtilen hususların aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Gizem Gözde ÖZŞAHİN

İÇİNDEKİLER

TEŞEKKÜR ..... **III**
ÖZET ..... **IV**
ABSTRACT ..... **V**
SİMGELER VE KISALTMALAR DİZİNİ ..... **VI**
ŞEKİLLER DİZİNİ ..... **VIII**
TABLOLAR DİZİNİ ..... **IX**
1. GİRİŞ **1**
2. GENEL BİLGİLER **4**
2.1. Sefalometrinin Tarihçesi **4**
2.2. Sefalometrik Radyografi Yöntemleri ve Kullanım Amaçları **5**
2.3. Sefalometrik Radyografinin Limitasyonları **7**
2.4. Görüntünün Elde Edilme Şekline Göre Sefalometrik Radyografi **7**
2.4.1. Geleneksel Sefalometrik Radyografi **7**
2.4.2. Dijital Sefalometrik Radyografi **8**
2.5. Posteroanterior (PA) Sefalometrik Radyografiler **9**
2.6. Posteroanterior Sefalometrik Analiz Yöntemleri **10**
2.6.1. Geleneksel Sefalometrik Analiz Yöntemi (El ile Çizim Yöntemi) **10**
2.6.2. Bilgisayar Destekli Dijital Sefalometrik Analiz Yöntemi **10**
2.6.3. Otomatik Sefalometrik Analiz Yöntemi **12**
2.7. Ortodontide Üç Boyutlu Görüntülemeye Neden İhtiyaç Vardır? **13**
2.8. Üç Boyutlu Görüntüleme Yöntemleri **13**
2.8.1. Manyetik Rezonans Görüntüleme (MRG) **13**
2.8.2. Ultrasonografi (USG) **14**
2.8.3. Bilgisayarlı Tomografi (BT) **15**
2.8.4. Konik Işınlı Bilgisayarlı Tomografi (KIBT) **15**
2.9. Yapay Zeka Nedir? **18**
2.10. Makine Öğrenmesi (Machine Learning, ML) **20**
2.11. Yapay Sinir Ağları (Artificial Neural Networks-ANN) **21**
2.11.1. Yapay Sinir Ağlarının Özellikleri **23**
2.11.2. Yapay Sinir Ağı Modelleri **25**

2.12. Derin Öğrenme ve Derin Evrişimli Sinir Ağları (DCNN) **28**
2.13. Evrişimli Sinir Ağı Katmanları **29**
2.13.1. Giriş Katmanı **29**
2.13.2. Evrişim Katmanı (Konvolüsyon Katmanı) **30**
2.13.3. Havuzlama Katmanı **30**
2.13.4. Tam Bağlı Katman **31**
2.13.5. Sınıflandırma Katmanı **31**
2.14. Evrişimli Sinir Ağlarının Eğitilmesi **31**
2.15. Aktivasyon Fonksiyonu **32**
2.16. Transfer Öğrenme **32**
2.17. Diş Hekimliğinde Yapay Zekâ ve Kullanım Alanları **33**
2.17.1. Ortodonti Alanında Yapay Zekâ **34**
3. MATERYAL VE METOT **36**
3.1. Hasta Seçimi **36**
3.2. Radyografik Veri Setinin Elde Edilmesi **36**
3.3. Veri Etiketleme **38**
3.4. Sefalometrik Radyograflar Üzerinde İşaretlenen Referans Noktalar **39**
3.4.1. İskeletsel İşaret Noktaları **39**
3.4.2. Dişsel İşaret Noktaları **41**
3.5. Derin Öğrenme Mimarisi **42**
3.6. Model Geliştirilmesi **44**
3.7. Eğitim Aşaması **44**
3.8. Model Performansının Değerlendirilmesi **47**
4. BULGULAR **48**
5. TARTIŞMA **58**
6. SONUÇ ve ÖNERİLER **65**
KAYNAKLAR **67**
EKLER **83**
EK-1. ÖZGEÇMİŞ **83**
EK-2. ETİK KURUL ONAYI **84**

TEŞEKKÜR

Uzmanlık eğitimim boyunca bilgi ve tecrübelerinde çok şey öğrendiğim, tez çalışmamda her daim bana yol gösteren değerli hocam ve tez danışmanım Dr. Öğr. Üy. Mehmet UĞURLU' ya,

Ortodonti uzmanlığım boyunca eğitimime önemli katkılarda bulunan hocalarım Doç. Dr. İlhan Metin DAĞSUYU, Doç. Dr. Rıdvan OKŞAYAN, Dr. Öğr. Üy. Fatih KAHRAMAN' a

Benim için her birinin ayrı ayrı çok değerli olduğu ve beraber çalışmaktan mutluluk duyduğum arkadaşlarım Seda Saliha KAYRAK, Gamze Çağla URUÇ, Özlem İNCE, Gülsen KAÇIRA KESKİN, Mehmet AYDIN, Simge SOYDAN, Melek KULAK, Hüseyin KARA, Jeyhun JAFARLI, Sahand GHAFFARI, İrem BALCI, Batuhan KULELİ, Zeki ARSLAN, Bircan KABUKÇU, Rabia TÜRK, Kerimcan AKTAŞ, İbrahim Taylan ÇELİK' e

Anabilim dalı hemşirelerimiz sevgili Meral DEMİR, Gönül ŞEN, Şemsi ARI ve sekreterimiz Nergis ERCAN' a,

Üzerimde sonsuz emek ve destekleri olan, her zaman sevgilerini hissettiğim canım ailem Nejla ÖZŞAHİN, Erdal ÖZŞAHİN, Merve ÖZŞAHİN ve Eftal KURT' a çok teşekkür ederim.

ÖZET

Konik Işınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Posteroanterior Sefalometrik (Frontal) Görüntüler Üzerinde Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometrik Noktaların Tespiti

Amaç: Bu çalışmanın amacı, konik ışınlı bilgisayarlı tomografi görüntülerinden elde edilen posteroanterior sefalometrik görüntüler üzerinde özel bir yapay zeka algoritması kullanılarak yapılan sefalometrik nokta tespitinin başarısını araştırmaktır.

Materyal ve Metot: Çalışmamızın veri setini 1295 hastanın ortodontik tedavi öncesi alınan konik ışınlı bilgisayarlı tomografi görüntülerinden elde edilen posteroanterior sefalometrik radyograflar üzerinde özel bir yapay zeka algoritması kullanılarak işaretlenen iskeletsel ve dişsel sefalometrik noktalar oluşturmaktır. Görüntüler üzerinde sefalometrik noktaların etiketlenmesi CranioCatch etiketleme yazılımı (CranioCatch, Eskişehir, Türkiye) kullanılarak yapılmıştır. Yapay zeka modelinin eğitimi, PyTorch uygulanan CNN tabanlı derin öğrenme yöntemi ile 300 Epoch kullanılarak gerçekleştirilmiştir. Modelin öğrenme oranı 0.0001 olarak belirlenmiştir.

Bulgular: Çalışmada eğitilen yapay zeka modelinde en yüksek SDR değeri Antegonial Notch, L, Antegonial Notch, R ve Gonion, L noktalarında bulunmuştur. En düşük SDR değeri Crista Galli noktasında gözlemlenmiştir. SDR değeri 2 mm' lik aralıkta 6 nokta haricinde %80 üzerinde başarı oranı göstermiştir.

Sonuç: Çalışmamız ilerleyen zamanlarda yapılacak olan derin öğrenme tabanlı KIBT raporlama sistemlerinin gelişimi açısından çok önemlidir. Bu sistemlerin klinik rutininde hekimlere zaman kazandırarak bir karar destek mekanizması rolü göreceği düşünülmektedir. Aynı zamanda sefalometrik noktaların tespiti sırasında, gözlemciler arası farkların ve gözlemcilerin farklı zamanlardaki değerlendirmelerinde oluşabilecek tutarsızlıkların minumuma indirilmesi konusunda çok yardımcı olacağı tahmin edilmektedir.

Anahtar Kelimeler: Derin öğrenme, KIBT, Sefalometrik nokta tespiti, Yapay zeka

ABSTRACT

Detection of Cephalometric Points with Artificial Intelligence Algorithms Improved by Deep Learning Method on Posteroanterior Cephalometric (Frontal) Images Obtained from Cone-Beam Computed Tomography Images

Aim: The aim of this study is to investigate the success of cephalometric point detection using a special artificial intelligence algorithm on posteroanterior cephalometric images obtained from cone beam computed tomography images.

Material and Method: The data set of our study is to create skeletal and dental cephalometric points marked using a special artificial intelligence algorithm on posteroanterior cephalometric radiographs obtained from cone beam computed tomography images taken before orthodontic treatment of 1295 patients. Labeling of cephalometric points on the images was done using CranioCatch labeling software (CranioCatch, Eskisehir, Turkey). The training of the artificial intelligence model was carried out using 300 Epochs with the CNN-based deep learning method applied to PyTorch. The learning rate of the model was determined as 0.0001.

Results: In the artificial intelligence model trained in the study, the highest SDR value was found at Antegonial Notch, L, Antegonial Notch, R and Gonion, L points. The lowest SDR value was observed at Crista Galli. The SDR value showed a success rate of over %80, except for 6 points in the 2 mm interval.

Conclusion: Our study is very important for the development of deep learning-based CBCT reporting systems to be made in the future. It is thought that these systems will play a role as a decision support mechanism by saving time for physicians in their clinical routine. At the same time, it is estimated that during the determination of cephalometric points, it will be very helpful in minimizing the differences between observers and the inconsistencies that may occur in the evaluations of the observers at different times.

Keywords: Artificial Intelligence, CBCT, Cephalometric point detection, Deep learning

SİMGELER VE KISALTMALAR DİZİNİ

°	Derece
%	Yüzde
<	Küçüktür
>	Büyüktür
≥	Büyük Eşit
≤	Küçük Eşit
kVp	Kilovolt
mA	Miliamper
µSv	Mikrosievert
mm	Milimetre
sn	Saniye
2B	İki Boyutlu
3B	Üç Boyutlu
A	A Noktası
AI	Artificial Intelligence (Yapay Zeka)
ANN	Artificial Neural Networks (Yapay Sinir Ağları)
ANS	Anterior Nasal Spine
AGR-AGL	Sağ ve Sol Antegonion Noktaları
Ark.	Arkadaşları
BT	Bilgisayarlı Tomografi
CdR-CdL	Sağ ve Sol Condylon Noktaları
CG	Crista Galli Noktası
CNN	Convolutional Neural Networks (Evrişimli Sinir Ağları)
DCNN	Derin Evrişimli Sinir Ağları
DICOM	Digital Imaging and Communications in Medicine)
DL	Deep Learning (Derin Öğrenme)
FR	Özellik İyileştirme Ağı
GoR-GoL	Sağ ve Sol Gonion Noktaları
ISBI	Uluslararası Biyomedikal Görüntüleme Sempozyumu

JR-JL	Sağ ve Sol Jugular Process Noktaları
KIBT	Konik Işınlı Bilgisayarlı Tomografi
LoR-LoL	Sağ ve Sol Latero-Orbitale Noktaları
L3CR-L3CL	Sağ ve Sol Lower Cuspid Tip Noktaları
L6CR-L6CL	Sağ ve Sol Lower Molar Buccal Cusp Noktaları
L6RR-L6RL	Sağ ve Sol Lower Molar Buccal Root Noktaları
Me	Menton Noktası
ML	Machine Learning (Makine Öğrenmesi)
MRE	Mean Radial Error (Ortalama Radyal Hata)
MRG	Manyetik Rezonans Görüntüleme
MSFA	Özellik Toplama Ağı
NCR-NCL	Sağ ve Sol Lateral Wall of Nasal Cavity
NS	Nasal Septum Noktası
PA	Postero-Anterior
ROR-ROL	Sağ ve Sol Supraorbitale Noktaları
SD	Standart Sapma
SDR	Başarı Tespit Oranı
SSD	Single Shot Multibox Detector
TME	Temporomandibular Eklem
USG	Ultrasonografi
U6CR-U6CL	Sağ ve Sol Upper Molar Buccal Cusp Noktaları
U6RR-U6RL	Sağ ve Sol Upper Molar Buccal Root Noktaları
YOLOv3	You-Only-Look-Once version 3
ZAR-ZAL	Sağ ve Sol Zygomatic Arch Noktaları
ZR-ZL	Sağ ve Sol Z Noktaları

ŞEKİLLER DİZİNİ

Şekil No **Sayfa No**

Şekil 2.1. Turing testi …… 18

Şekil 2.2. Yapay zekâyı oluşturan temel kavramlar…… 19

Şekil 2.3. Biyolojik sinir hücresi ve yapay sinir ağı …….. 21

Şekil 2.4. Yapay sinir ağı nöron modeli …… 22

Şekil 2.5. Tek katmanlı algılayıcı modeli …….. 24

Şekil 2.6. Çok katmanlı algılayıcı model ……... 25

Şekil 2.7. İleri beslemeli ağ yapısı ……. 26

Şekil 2.8. Geri beslemeli ağ yapısı ……. 26

Şekil 2.9. a) Makine öğrenmesi, b) Derin öğrenme …… 27

Şekil 2.10. DCNN mimarisi …… 28

Şekil 2.11. Evrişim işlemi …….. 29

Şekil 2.12. Havuzlama örneği …… 29

Şekil 3.1. Romexis programından KIBT görüntüsünün dışa aktarımı …….. 35

Şekil 3.2. Dolphin İmaging programında baş pozisyonunun ayarlanması … 35

Şekil 3.3. Dolphin İmaging programında sefalometrik radyograf oluşturulması 36

Şekil 3.4. Sefalometrik noktaların CranioCatch programında etiketlenmesi .. 37

Şekil 3.5. Özellik toplama ve iyileştirme ağının (FARNet) mimarisi …… 41

Şekil 3.6. Farnet mimarisi ile gerçekleştirilen diş tespit modelinin gelişim aşamalarının diyagramı …… 44

Şekil 4.1. Test sonucu görüntülerinin değerlendirilmesi-1 54

Şekil 4.2. Test sonucu görüntülerinin değerlendirilmesi-2 …… 55

TABLOLAR DİZİNİ

Tablo No **Sayfa No**

Tablo 2.1. Biyolojik sinir hücresi ve yapay sinir ağı terminolojisi …….. 21

Tablo 3.1. Veri seti sınıflandırılması ……... 43

Tablo 4.1. Sefalometrik nokta tespitinin SDR ve MRE değerleri …… 53

1. GİRİŞ

Ortodontik anomalinin teşhis ve tedavi planlamasında klinik muayene gözlemlerinin yanında fotoğraflar, alçı modeller ve radyografilerden faydalanılmaktadır. Sefalometri birçok sınırlamalarına rağmen önemli bir teşhis yöntemidir.[1] Sefalometrik analizler hastadaki anomalinin dişsel mi iskeletsel mi olduğunu belirlemek, ortodontik tedavi planı yapmak, büyüme-gelişim sırasında oluşan değişiklikleri gözlemlemek, ortodontik tedavi sürerken ve sonrasında meydana gelen değişimleri belirlemek amacıyla yapılabilir.[2]

Sefalometrik radyograflar, lateral ve posteroanterior (frontal) sefalometrik radyograflar olmak üzere ikiye ayrılmaktadır. Lateral sefalometrik radyografiler ile ön-arka yönde iskeletsel, dişsel ve yumuşak doku morfolojisi ile ilgili veriler elde edilir.[3] Posteroanterior sefalometrik radyografiler; yatay düzlemde maksilla ve mandibulanın genişliğinin değerlendirilmesinde, bilateral iskeletsel ve dişsel yapıların dikey yön ilişkilerinin belirlenmesinde, diş arklarının kemik kaidesiyle olan genişlik ve açısal ilişkisinin değerlendirilmesinde, nazal kavite genişliğinin ölçülmesinde, maksilla-mandibuladaki iskeletsel ve dişsel asimetrilerin tespit edilmesinde ve de vertikal ve transvers fasiyal asimetrilerin belirlenmesinde yardımcı olmaktadırlar.[4, 5]

Daha yaygın olarak yararlanılan lateral sefalometrik radyografilere ilave olarak posteroanterior sefalometrik radyografiler dentofasiyal bölgenin incelenmesinde önemli bir etkendir.[6] Geçmişte ortodontide sıklıkla sagittal düzlemdeki ilişkiler incelendiği için çoğu ortodontist posteroanterior radyografileri kullanmazken, bazı önemli etmenler ortodontistleri transvers boyutla ilgilenmeye itmiştir.[7] Bu faktörlerden birkaçı; hızlı maksiller ekspansiyon, hafif tellerin mandibular arkın lateral genişlemesinde etkili

olması, transvers görünüşü vurgulayan dolgun ve çarpıcı gülüşün kabul görmesi, [8] kraniyal ve mandibular asimetrilerin tedavi planlamalarında önemli bir etken olması, [9] frontal estetiğin apertura piriformis asimetrileri ve nazal genişlikten etkilenmesi durumlarıdır.[10]

Elde edilen sefalometrik radyograflar üzerinde analiz yöntemi olarak uzun yıllardır kullanılan el ile çizim tekniğinde, sefalometrik film üzerine yerleştirilen asetat kağıdına istenen anatomik noktalar işaretlenir. Bu çizimler kullanılarak açısal ve doğrusal ölçümler elde edilir. Ancak bu teknik oldukça zaman alıcı ve hataya çok müsait olduğundan aynı zamanda bilgisayar teknolojisindeki gelişmeler sonucu bilgisayar destekli dijital sefalometrik analiz yöntemi yaygın olarak kullanılmaya başlanmıştır.[11, 12] Dijital ortamdaki sefalometrik görüntüler çeşitli yollarla programa aktarılır ve üzerlerinde referans noktaları belirlenir. Analiz metotlarından bir veya birkaçı kullanılarak sonuç elde edilir. Analiz bilgisayar tarafından yapıldığı için ölçüm esnasında oluşabilecek hataların önüne geçildiği savunulmaktadır ancak referans noktalar klinisyen tarafından belirlendiği için konvansiyonel sefalometrik analiz metoduna benzer hataların burada da oluşabileceği belirtilmiştir.[11, 13] Bunun sonucunda otomatik sefalometrik analiz yöntemi geliştirilmiştir. Bu analizde yazılım tarafından, referans noktaları otomatik olarak belirlenir ve gerekli ölçümler yapılır. Otomatik analizdeki en önemli faktör anatomik noktaların belirlenmesidir çünkü ölçüm işlemleri, bilgisayar destekli sefalometrik analiz yöntemlerinde de hemen hemen hatasız yapılmaktadır.[14]

Eski zamanlardan beri araştırmacılar, insanın düşünme ve karara varma mekanizmasını taklit etmeyi amaçladılar. Bu çalışmalar sonucunda ortaya çıkan yapay zeka teknolojisi, insan zekasına ihtiyaç duyan görevleri gerçekleştirebilen sistemler meydana getirmeyi hedefleyen bilim dalı olarak açıklanabilir.[15] Son zamanlarda yapay zeka teknolojisinin hızlı gelişimi günlük yaşamın birçok alanına etki etmiştir bunun

sonucu olarak yapay zeka uygulamaları diş hekimliğinin birçok dalı için popüler hale gelmeye başlamıştır. Yapay zeka diş hekimliğinde, asıl olarak yüksek kalitede hasta bakımı ile beraber, uygulanan tedavilerde olabilecek en iyi sonuçların sağlanmasında büyük rol oynayan tanı sürecini mümkün olabildiğince en doğru hale getirmek amacıyla kullanılmaktadır. Yapay zekanın diş hekimlerinin hayatına girmesiyle birlikte insan kaynaklı hataları azaltıp zamandan ve maliyetten kazanç sağlaması amaçlanmaktadır. Diş hekimlerinin doğru bir karara ulaşmak için sıkıntı yaşadıkları durumlarda daha başarılı kararlar alabilmeleri için onları yönlendirici bir sistemdir.[16, 17]

Ortodontide; tanı tedavi protokollerinde, büyüme gelişim döneminin tespit edilmesinde, anatomik noktaların belirlenmesinde, iskeletsel sınıflandırmada, çekimli-çekimsiz tedavi seçiminde ve ortognatik cerrahi gibi çok sayıda alanda yapay zeka modellerinden yararlanılmaktadır.[18, 19] Ortodontik teşhis ve tedavi planlaması ile ilgili olarak, yapay zeka teknolojisinin geliştiricileri, sefalometrik radyografi görüntülerinden sefalometrik nokta işaretlerini çok az insan etkileşimi ile otomatik olarak tanımlamayı hedeflemektedir.[20] Bu araştırmanın amacı, özel bir yapay zeka algoritması kullanılarak yapılan analizlerin doğruluğunu mevcut altın standart yöntemlerle (uzmanları tarafından gerçekleştirilen analizler) karşılaştırmaktır. Çalışmamızda ortodontik ölçüm tayininde oluşabilecek gözlemciler arası farkların ve gözlemcilerin farklı zamanlardaki değerlendirmelerinde gözlenebilecek tutarsızlıkların minimuma indirilmesi amaçlanmıştır. Sefalometrik radyograflardan veri seti oluşturmak için daha önceden kliniğimize başvurmuş hastaların üç boyutlu radyografik arşiv kayıtlarının kullanılması planlanmıştır.

2. GENEL BİLGİLER

2.1. Sefalometrinin Tarihçesi

İnsanlardaki baş-yüz gelişiminin bilimsel olarak değerlendirilmesine farklı boyut ve şekillerdeki çok sayıda kafatası üzerinde incelemelerde bulunan antroplog ve anatomistler tarafından başlanmıştır. Kafatasları üzerinde çeşitli ölçümler yapılmış ve bu ölçümlere kraniyometri adı verilmiştir. Daha sonraları bu çalışmalara canlılar üzerinde devam edilmiş ve sefalometri adını almıştır.[6] Ancak ölçümler deri ve yumuşak dokudan palpasyon yöntemiyle yapıldığı için sonuçlar hiçbir zaman tam manasıyla doğru olamaz.

Diş hekimliği alanında Wilhelm Conrad Röntgen tarafından 1895 yılında X ışınlarının keşfiyle devrim yaşanmıştır. Elde edilen 2 boyutlu kafa görüntüleriyle bu görüntüler üzerinde belirlenen sert ve yumuşak dokulardaki noktalar aracılığıyla çeşitli ölçümler yapılmaktadır. Yapılan bu ölçümler sonucunda kraniyofasiyal büyüme ve gelişim değerlendirilmesinde doğru bir şekilde incelemeler yapılabilir.[21]

1921 yılında Pacini sıradan antropometriye göre röntgen ışını antropometrisinin ölçüm doğruluğunun çok daha fazla olduğunu belirtmiştir. Başın dikey bir başlık ile desteklenmiş olduğu ve film median sagittal düzleme paralel olacak şekilde yerleştirildiği bir teknik geliştirmiştir. Bu yöntemle alınan röntgenler üzerinde pogonion, nasion, gonion, spina nasalis anterior, meatus acusticus externus'un üst noktası, acustion, sella turcica'nın orta noktası gibi noktaları tanımlamıştır.[21, 22]

1931 yılında Broadbent bir makale yayımlamış ve daha önceki uygulamalardan daha gelişmiş bir teknik ortaya koymuştur. Bu teknik sonrasında sefalometride büyük bir ilerleme kaydedilmiş ve giderek günümüzdeki modern uygulamasına kavuşmuştur.[23]

Ortodonti literatürüne sefalometrinin girmesinin ardından birçok araştırmacı tarafından farklı analizler geliştirilmiştir. Tweed (1946), Downs (1948), Steiner (1953), Sasounni (1955), Ricketts (1960), Jarabak ve Fizzell (1972), Hasund (1974), Jacobson (1975) ve McNamara (1984) gibi araştırıcılar kendi isimleri ile sefalometrik analiz yöntemleri oluşturmuşlardır.

2.2. Sefalometrik Radyografi Yöntemleri ve Kullanım Amaçları

Ortodontik anomalinin teşhis ve tedavi planlamasında klinik muayene gözlemlerinin yanında fotoğraflar, alçı modeller ve radyografilerden faydalanılmaktadır. Sefalometri birçok sınırlamalarına rağmen önemli bir teşhis yöntemidir.[1]

Lateral sefalometrik radyografiler ile yalnızca ön-arka ve dikey yönde değerlendirmeler yapılabilmektedir. Başın ön-arka, dikey ve yatay yönleri içerecek şekilde değerlendirilebilmesi için bu radyografilere ek olarak posteroanterior (PA) ve submentoverteks (SMV) radyografik görüntüler de kullanılmadır.[24]

Sefalometrik analizler hastadaki anomalinin dişsel mi iskeletsel mi olduğunu belirlemek, ortodontik tedavi planı yapmak, büyüme-gelişim sırasında oluşan değişiklikleri gözlemlemek, ortodontik tedavi sürerken ve sonrasında meydana gelen değişimleri belirlemek amacıyla yapılabilir.[2]

1961 yılında Ricketts sefalometrik radyografinin kullanım amaçlarını 4C kuralı ile formüllendirmiştir; [25]

1-Karakterize etme (chararacterise): Anomalinin; patolojik, anatomik veya morfolojik olduğunu saptamaya yarar.

2-Kıyaslama (compare) : Aynı bireyin değişik yaşlarında veya farklı bireyler arasında karşılaştırma yapmaya yarar.

3- Sınıflama (classfie) : İskeletsel ve dişsel açıdan çene, çene kemiği ve dişler düzeyinde farklı sınıflamalar yapmaya yarar.

4- İletişim kurma (communicate) : Hastanın belirlenen durumunu diğer hekimlerle veya hastanın ailesiyle paylaşmaya yarar.

Lateral sefalometrik radyografiler ile ön-arka yönde iskeletsel, dişsel ve yumuşak doku morfolojisi ile ilgili veriler elde edilir. Posteroanterior sefalometrik radyografiler ile transversal yönde iskeletsel ve dişsel ilişkiler ile ilgili veriler sağlar, aynı zamanda iskeletsel ve dental asimetrilerin tanımlanmasını sağlar.[3]

Kraniyofasiyal görüntülemenin amacı aşağıdaki bölümlerin bir veya birden fazlasının incelenmesidir:

1-Normal ve anormal yapıların tespiti

2-Çene boyutu ve gereken diş mesafesi arasındaki ilişkinin belirlenmesi

3-Kök uzunluğunun incelenmesi

4- Temporomandibular eklemin durumumun incelenmesi

5- Kraniyofasiyal gelişme yönünün ve boyutunun tahmin edilmesi

6- Gömülü ve supernumerer dişlerin saptanması

7- Üst ve alt çenenin uzaydaki ilişkisinin tespiti

8- Tedavinin kraniyofasiyal anatomideki etkisinin gözlemlenmesi[3]

2.3. Sefalometrik Radyografinin Limitasyonları

Sefalometrik radyografilerin sık kullanımlarına rağmen birtakım kısıtlamaları mevcuttur. Bunlar:

1-Geleneksel kafa filmi, üç boyutlu yapıların iki boyutlu görüntüsüdür. Üç boyutlu nesneler iki boyutlu gösterildiğinde, görüntülenen yapılar, dikey ve yatay olarak yer değiştirir.[26]

2- Sefalometrik noktalar ve anatomik yapılar midsagittal düzlem üzerinde değildir ve çoğunlukla çift taraflı bulunurlar. Bu sebeple radyografide çift görüntü verirler.

3- Kaynaktan çıkan birbirine paralel olmayan x ışınları sebebiyle görüntüde magnifikasyonlar meydana gelir.[27]

4-. Anatomik yapıların iyi belirlenememesi, zor saptanan kenar ve gölgeler ile hasta konumlandırmadaki yanlışlar sebebiyle, anatomik noktaların saptanmasında hatalar oluşabilir.[28-30]

2.4. Görüntünün Elde Edilme Şekline Göre Sefalometrik Radyografi Çeşitleri

2.4.1. Geleneksel Sefalometrik Radyografi

Geleneksel sefalometrik radyografiler; kafa kemiklerinin, yüzün ve çene kemiklerinin lateral yönden görüntülenebildiği ekstraoral radyografilerdir. Görüntü kaset içerisine yerleştirilen röntgen filmine X ışını düşürülmesiyle elde edilir. Kasetin içerisinde bulunan 2 ranforsatör arasına film yerleştirilmiştir. Filmler dıştan içe doğru sırasıyla; koruyucu tabaka, emülsiyon tabakası, yapıştırıcı tabaka ve baz tabakadan

oluşur. Baz tabaka tahmini 0.2 mm kalınlığında polyester polietilen veya selüloz asetattan oluşmaktadır. Yapıştırıcı tabaka emülsiyonun baz tabakaya bağlanmasını sağlar. Görüntünün meydana geldiği yer ise emülsiyon tabakasıdır, banyo solüsyonuyla bu tabakada bulunan X ışınlarına duyarlı gümüş halid kristallerinin reaksiyonu sonucunda görüntü oluşur. En dışta bulunan koruyucu tabaka emülsiyon tabakasını dış faktörlerden korur. Dokuların farklı yoğunluklarda olması sebebiyle X ışını dokuya ulaştığında yapılarda farklı oranlarda absorbe olur ve bu nedenle filmde açık ve koyu renk alanlar oluşur. Işınlanmış film banyo işlemleri sonucunda radyografik görüntüye dönüşür.[31]

Günümüzde yaygın kullanımına rağmen geleneksel sefalometrik radyografi, dijital görüntüleme tekniklerine kıyasla oldukça dezavantajlıdır. Bu görüntüleme şeklinde görüntünün oluşturulma süreci zaman alıcıdır. Filme tabi tutulan kimyasal işlemlerin süresine göre görüntü kalitesi değişebilir. Görüntü oluştuktan sonra üzerinde işlem yapmak mümkün değildir.[32]

2.4.2. Dijital Sefalometrik Radyografi

Bilgisayar teknolojisinin yıllar içindeki gelişmeleri sonucu dijital sefalometrik radyografilere olan rağbet giderek artmıştır. İmaj reseptörü olarak dijital sensörler röntgen filminin yerini almıştır. X ışını bu sensörler üzerine düşürülerek görüntüye ulaşılır. Elde edilen görüntü bilgisayara nakledilir ve bilgisayarda depolanır.[33]

Dijital görüntü ‘piksel’ adı verilen birimlerden oluşmaktadır. Piksellerin boyutu küçüldükçe ve sayısı arttıkça görüntünün çözünürlüğü artar ve görüntü daha ayrıntılı hale gelir.[34]

Dijital olarak elde edilen görüntüler konvansiyonel yönteme göre daha hızlı elde edilir ve banyo yapma zorunluluğu olmadığı için daha az çevre kirliliği oluşur. Görüntüler

dijital ortamda daha kolay paylaşılır. Elde edilen görüntüler üzerinde değişiklikler yapılabilir bununla birlikte ışınlama sırasındaki hatalar düzeltilebilir. İntraoral görüntülemelerde maruz kalınan radyasyon oranı konvansiyonel yönteme göre daha azdır, ekstraoral görüntülemelerde ise anlamlı bir fark bulunmamıştır.[35]

2.5. Posteroanterior (PA) Sefalometrik Radyografiler

Posteroanterior sefalometrik radyografiler; yatay düzlemde maksilla ve mandibulanın genişliğinin değerlendirilmesinde, bilateral iskeletsel ve dişsel yapıların dikey yön ilişkilerinin belirlenmesinde, diş arklarının kemik kaidesiyle olan genişlik ve açısal ilişkisinin değerlendirilmesinde, nazal kavite genişliğinin ölçülmesinde, maksilla-mandibuladaki iskeletsel ve dişsel asimetrilerin tespit edilmesinde ve de vertikal ve transvers fasiyal asimetrilerin belirlenmesinde yardımcı olmaktadırlar.[4, 5]

Daha yaygın olarak yararlanılan lateral sefalometrik radyografilere ilave olarak posteroanterior sefalometrik radyografiler dentofasiyal bölgenin incelenmesinde önemli bir etkendir.[6] Geçmişte ortodontide sıklıkla sagittal düzlemdeki ilişkiler incelendiği için çoğu ortodontist posteroanterior radyografileri kullanmazken, bazı önemli etmenler ortodontistleri transvers boyutla ilgilenmeye itmiştir.[7] Bu faktörlerden birkaçı; hızlı maksiller ekspansiyon, hafif tellerin mandibular arkın lateral genişlemesinde etkili olması, transvers görünüşü vurgulayan dolgun ve çarpıcı gülüşün kabul görmesi, [8] kraniyal ve mandibular asimetrilerin tedavi planlamalarında önemli bir etken olması, [9] frontal estetiğin apertura piriformis asimetrileri ve nazal genişlikten etkilenmesi durumlarıdır.[10]

Gottlieb ve arkadaşları, araştırmalarında, ortodontistlerin yalnızca %13.3' ünün hastalarından düzenli olarak posteroanterior sefalometrik radyografi kayıtları

topladıklarını rapor etmişlerdir. Bu oranın az olması ortodonti eğitim merkezlerinde frontal sefalometrik değerlendirmenin öneminin yeteri kadar belirtilmemesi ya da uygulama esnasında karşılaşılan bazı zorluklarla ilişkilendirilebilir. Uygulamadaki bu sorunlar arasında baş konumunun tekrarlanmasındaki zorluklar, oluşumların superpozisyonları sebebiyle anatomik noktaların tespitindeki zorluklar, hastanın ilave radyasyona maruz kalması, radyografi tekniğinin zayıflığı sayılabilir.[36]

2.6. Posteroanterior Sefalometrik Analiz Yöntemleri

2.6.1. Geleneksel Sefalometrik Analiz Yöntemi (El ile Çizim Yöntemi)

Çok önceden beri kullanılan bu yöntem ile sefalometrik film üzerine yerleştirilen asetat kağıdına istenen anatomik noktalar işaretlenir. Bu çizimler kullanılarak açısal ve doğrusal ölçümler elde edilir. Çizim yapılan ortamın karanlık olması ve negatoskop kullanılarak yapılması tercih edilir. Ancak bu teknik oldukça zaman alıcıdır ve hataya çok müsaittir.[11, 12] Hatalar çoğunlukla anatomik noktaların belirlenmesi sırasında oluşmaktadır. Bunun da araştırmacının tecrübesinden ve görüntünün yoğunluğu ve keskinliği gibi etmenlerden etkilenen referans noktalarının tespiti sırasında oluştuğu gözlenmektedir.[29, 37]

2.6.2. Bilgisayar Destekli Dijital Sefalometrik Analiz Yöntemi

Bilgisayar teknolojisindeki gelişmeler sonucu geleneksel analiz yöntemine rağbet azalmıştır ve bilgisayarlara yüklenmiş olan veriler kullanılarak inceleme yapılmaktadır.

Dijital ortamdaki sefalometrik görüntüler çeşitli yollarla programa aktarılır ve üzerlerinde referans noktaları belirlenir. Analiz metotlarından bir veya birkaçı kullanılarak sonuç elde edilir. Analiz sonucu açısal, doğrusal ya da oransal ölçümler saniyeler içinde sağlanır ve sonuçlar yazıcıdan çıktı şeklinde alınabilmektedir.[38-40] Analiz bilgisayar tarafından yapıldığı için ölçüm esnasında oluşabilecek hataların önüne geçildiği savunulmaktadır ancak referans noktalar klinisyen tarafından belirlendiği için konvansiyonel sefalometrik analiz metoduna benzer hataların burada da oluşabileceği belirtilmiştir.[11, 13]

Bilgisayarlı sefalometrik analiz sistemleri; birinci, ikinci ve üçüncü nesil sistemler olarak bölümlendirilebilir.

Birinci nesil sistemlerde geleneksel radyografilerin çizimi dijital ortama aktarılıp sonuçlar analiz programında ölçülmektedir. Referans noktalarının dijital ortama aktarılabilmesi için dijitizer ve cursor adı verilen ekipmanlara gerek vardır. [41]

İkinci nesil sistemlerde dijitizer ve cursora gerek duyulmamaktadır. Dijital kamera veya tarayıcı gibi düzenekler kullanılarak elde edilen görüntüler bilgisayara aktarılıp görüntü üzerinde çizim ve ölçümler yapılmaktadır.[42]

Üçüncü nesil sistemlerde ışığa duyarlı fosfor plaklar, şarj bağlı cihaz reseptörleri ya da direkt dijital sistemler sayesinde elde edilen görüntüler doğrudan bilgisayar ortamına aktarılır ve görüntüler üzerinde işaretleme ve analiz yapılmaktadır. Doğrudan dijital görüntü oluşturulduğu için banyo gereksiniminin ortadan kalkması, görüntüleri işleme, aktarma ve arşivleme işlemlerinin daha basit ve daha hızlı olmasından dolayı üçüncü nesil sistemler diğerlerine göre daha ideal bir sistem olarak görülmektedir.[33, 43]

2.6.2.1. Bilgisayar Destekli Dijital Sefalometrik Analiz Yazılımları

Günümüzde çok sayıda marka adı altında dijital sefalometrik analiz programı vardır: Ceph Smile Plus, Dolphin, Dr. Ceph, Dentofacial Planner, Dentrix Image, Dr.Ceph Jr. Dr.View, Nemoceph, IOPS, JOE, Niamtu Imaging Systems, OPAL, Onyx Ceph, Orthoview-Ceph, Vistadent, Prescription Planner/Portrait, Screenceph, Quick ceph 2000, T PhotoEze bunlardan bazılarıdır. Bu programların güvenilirliğini inceleyen ve konvansiyonel yöntemlerle karşılaştıran çalışmalar mevcuttur.[40, 44] Bu çalışmalar sonucunda dijital sefalometrik analiz programlarının zamandan kazanç sağladığı yönünde görüşler belirtilmiştir ve de güvenle geleneksel analiz yöntemine karşılık olarak kullanılabileceği ileri sürülmüştür.[45, 46]

2.6.3. Otomatik Sefalometrik Analiz Yöntemi

Bu yöntemle el ile yapılan analiz esnasında oluşabilecek hataları ve sarf edilen zamanı azaltmak amaçlanmaktadır.[14] Sefalometrik analizdeki hatalar sıklıkla anatomik noktaların işaretlenmesinde, çizim esnasında veya ölçüm sırasında oluşan sistematik hatalardır.[28, 41, 47] Bilgisayar destekli sefalometrik analiz programları ile ölçüm esnasında oluşan mekanik hatalar engellenir ancak anatomik noktaların işaretlenmesi sırasındaki tutarsızlık engellenememektedir.[28, 41] Bilgisayar destekli sefalometrik analiz geleneksel yöntem kadar değilse de yine de zaman alıcı bir yöntemdir.[14] Analizin sağlanması için gereken sürenin azaltılması ve referans noktaların daha sağlıklı belirlenmesinin sağlanması gayesiyle otomatik sefalometrik analiz girişimleri olmuştur.[48] Bu analizde yazılım tarafından, referans noktaları otomatik olarak belirlenir ve gerekli ölçümler yapılır. Otomatik analizdeki en önemli faktör anatomik noktaların belirlenmesidir çünkü

ölçüm işlemleri, bilgisayar destekli sefalometrik analiz yöntemlerinde de hemen hemen hatasız yapılmaktadır.[14]

2.7. Ortodontide Üç Boyutlu Görüntülemeye Neden İhtiyaç Vardır?

Görüntüler geleneksel ve dijital yöntemlerle iki boyutlu olarak elde edildiğinde anatomik oluşumlar yatay ve dikey olarak yer değişikliğine uğramaktadırlar aynı zamanda dokular birbirleri içerisine girmektedirler.[49, 50] Median düzlemin her iki tarafında bulunan anatomik noktaların çift görüntü oluşturması, görüntü netliğindeki yetersizlikler sebebiyle kolaylıkla ayırt edilemeyen kenar ve gölgelerin olması anatomik noktaların doğru işaretlenmesine engel olmaktadır.[49, 51] Bu sebeple üç boyutlu anatomik yapılar hakkında gerekli bilgilerin alınması engellenir ve tam anlamıyla doğru bir tedavi planı oluşturulamayacağı yönünde tartışmalar olmuştur.[29, 52] Bütün bunların sonucunda, üç boyutlu sefalometrik analizin klinikte rutin olarak kullanılmasına yönelik çalışmalarda bulunulmuştur. Baumrind 1970 ve 1980'li yıllarda bu çalışmalara öncülük eden kişi olmuştur.[53] Sonraki yıllarda üç boyutlu görüntüleme tekniklerinin bulunmasıyla üç boyutlu sefalometrik analiz de klinikteki yerini almıştır.

2.8. Üç Boyutlu Görüntüleme Yöntemleri

2.8.1. Manyetik Rezonans Görüntüleme (MRG)

Yöntem manyetik ortamda hastaya radyo dalgası gönderilerek vücut yapılarında manyetik etkiyi değiştirme, akabinde yine manyetik alanın tesirine geçerken yapılardan gelen sinyalleri toplayarak görüntü oluşturma esasına dayanır. Yöntemde vücutta mevcut

olan, manyetik özelliği bulunan atomlardan faydalanılmaktadır.[54] Bu atomlar arasında hidrojen atomu, çekirdeğinde bir proton olması, vücutta fazla miktarda bulunması ve çok iyi sinyal vermesi gibi özelliklerinden dolayı görüntülemede en kazançlı olanıdır. Görüntü kalitesi görüntülenen yapıdaki hidrojen atomu miktarıyla doğrudan bağlantılıdır. Serbest hidrojen atomunun kortikal kemik, diş minesi gibi sert dokularda az sayıda bulunması sebebiyle bu yapılarda MRG yöntemi ile istenilen kalitede görüntüler oluşturulamamaktadır. Yumuşak dokuların görüntülenmesinde ise oldukça başarılı bir yöntemdir. Diş hekimliğinde MRG, Temporomandibular Eklem (TME) diski ve bu alandaki patolojilerin, tükürük bezi hastalıklarının, lenf nodülleri ve kaslarda oluşan değişikliklerin, yumuşak dokularda gözlenen kist ve tümörlerinin incelenmesinde kullanılır.[55] Bu avantajlarına karşın maliyetinin yüksek olması bu yöntemin dezavantajıdır.[56]

2.8.2. Ultrasonografi (USG)

Son zamanlarda baş-boyun bölgesinde kullanılması oldukça ilgi gören ultrasonografi diğer tekniklerden radyasyon ve elektromanyetik içermemesiyle ayrılır. Ultrasonografide ses enerjisi kullanılmaktadır. Ultrasonografi cihazları, ilettikleri sesin vücutta doku ara yüzeylerinden yansıması neticesiyle gelen ekoları kaydederek görüntü meydana getirmektedir. Yansımaları belirleyen unsur, dokuların ses direncinin birbirlerinden farklı olmasıdır. Birbirine komşu iki dokunun sese direnci arasındaki fark fazla ise ara yüzeyden yansıma daha çok olacaktır, az ise yansıma az olacaktır. Bu yansımalar aygıtın ekranında parlak beyaz noktalar şeklinde görülmektedirler.[57]

Ultrasonografik görüntüleme, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRI) ile kıyaslandığında iyonize radyasyonun içermeyen, hızlı, ekonomik, tekrarlanabilir ve invaziv olmayan bir tanı yöntemidir.[58, 59]

2.8.3. Bilgisayarlı Tomografi (BT)

1972 yılında Goldfrey Hounsfield tarafından geliştirilen bilgisayarlı tomografide görüntüler kesitsel olarak elde edilmektedir.[60, 61] Bilgisayarlı tomografide kesit görüntünün elde edilebilmesi, röntgen tüpü ve dedektörlerin hastanın çevresinde döndürülmesi ile olmaktadır. Elde edilen görüntüler ile sert ve yumuşak doku değerlendirilmesi, baş - boyun patolojileri ve TME incelenmesi, anomaliler ve neoplastik durumlar tanımlanabilir.[62]

Bilgisayarlı tomografi aygıtlarının ebat olarak geniş alan kaplamaları, pahalı olmaları, radyasyon dozunun fazla olması, sert doku çözünürlüğünün fazla yeterli olmaması ve cihaza ulaşım güçlüğü diş hekimliğinde kullanımını kısıtlamaktadır.[63]

2.8.4. Konik Işınlı Bilgisayarlı Tomografi (KIBT)

1998 yılında Mozzo ve arkadaşları tarafından geliştirilen KIBT, diş hekimliğinde kullanılmaya başlanmıştır.[64] KIBT' de spiral bilgisayarlı tomografide kullanılmakta olan yelpaze şeklindeki X ışınının yerini konik şekilli X ışını fotonları almıştır. Görüntülenecek yapı çevresinde 360 derecelik tarama gerçekleştirilir. Elde edilen ham görüntüler görüntü verilerini oluştururlar, yazılım programları tarafından da bu verilerden üç boyutlu hacimsel görüntüler elde edilir.[65] KIBT cihazlarının BT' ye göre maliyetinin

daha az olması ve daha küçük yer kaplamaları dolayısıyla bu görüntüleme diş hekimliğinde sıklıkla tercih edilmektedir.[66]

2.8.4.1. KIBT' nin Avantajları

• Küçük alanların taranmasına olanak sağlamasıyla hastanın maruz kaldığı radyasyon dozu daha azdır,[67]

• KIBT cihazları, BT cihazları ile kıyaslandığında boyutları daha küçüktür dolayısıyla daha az yer kaplar,[68]

• Kullanılan vokseller izotropik olduğu için görüntü netliği, voksel boyutu anizotropik olan bilgisayarlı tomografi görüntüleme tekniğine göre daha iyidir. Aynı zamanda voksel boyutunun da BT'ye göre daha küçük olması çözünürlük kalitesinde artış meydana getirmektedir,[69]

• Maliyetleri BT' ye kıyasla daha azdır,[70]

• Işınlama süresinin daha kısa olması sonucu, BT' den elde edilen görüntülere kıyasla KIBT' den elde edilen görüntülerde metal objelerin çevresinde oluşan artefaktlar daha azdır.[71]

2.8.4.2. KIBT' nin Dezavantajları

• KIBT' nin, kontrast çözünürlüğü fazla olan BT' ye göre yumuşak doku görüntülenmesi daha başarısızdır,[72]

• Medikal BT' ye göre daha az maliyetli olmalarına karşın, geleneksel görüntüleme yapan cihazlara kıyasla maliyetleri fazladır bu da rutin olarak kullanımı zorlaştırmaktadır,[73]

• Uygulanımı teknik hassasiyet gerektirmektedir. Aygıtın çalışma prensiplerine hakim olunması fazlasıyla önemlidir bununla birlikte görüntüsü alınmak istenen alana uygun doz düzenlemesi yapılmalıdır. Elde edilen görüntülerin başarılı bir şekilde yorumlanabilmesi amacıyla programın çalışma sistemiyle alakalı eğitim alınması da gereklidir,[52]

• Metal restorasyonlar, implantlar, kök kanal dolguları metal artefaktına sebep olurlar.[74]

2.8.4.3. KIBT' nin Ortodontide Kullanım Alanları

• Ortodontik anomalilerin teşhisinde ve değerlendirilmesinde,[75]

• Eksternal ve internal kök rezorpsiyonlarının belirlenmesinde, köklerin boyut ve şekillerinin değerlendirilmesinde,[76]

• Gömülü ve supernumere dişlerin yerlerini saptamada ve komşuluğunda bulunan yapılarla ilişkisinin berlirlenmesinde,[75]

• TME morfolojisinin ve eklemdeki dejeneratif farklılıkların saptanmasında, eklemde kırık durumlarında, ortodontik tedavi neticesinde eklemdeki değişikliklerin belirlenmesinde,[77]

• Ortognatik cerrahi planlama sırasında,[75]

• Özellikle ortognatik cerrahi planlama sırasında oldukça işe yarayan yüz analizlerinin yapılmasında,[78]

• Tedavi öncesi ve sonrasındaki değişikliklerin saptanması amacıyla üç boyutlu çakıştırma yapılmasında,[78]

• Dudak-damak yarıklı bireylerde sefalometrik analiz yapılmasında, bu bireylere tatbik edilen kemik greftinin başarısının değerlendirilmesinde,[79, 80]

• Anomali türüne göre havayolu hacminin, şeklinin farklılığa uğraması sonucu oluşan değişikliklerin analiz edilmesinde,[81, 82]

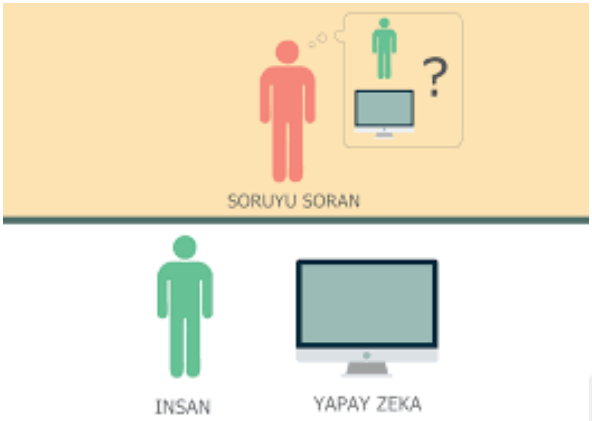
• Hızlı üst çene genişletmesi sonrası iskeletsel, dişsel olarak değişimlerin gözlenmesinde, nazal kavite hacmindeki farklılıkların analiz edilmesinde kullanılabilmektedir.[83]

2.9. Yapay Zeka Nedir?

Yapay zekâ, tanınmış mühendis John McCarthy' nin tarifiyle akıllı makineler yapımının bilimi ve mühendisliği manasına gelmektedir.[84] Bilim insanları çok uzun sürelerden beri makinelere insan gibi düşünebilme kabiliyeti kazandırabilme düşüncesindedirler. Bu konuyla ilgili çalışmaların başlangıcı Aristotales dönemine kadar uzanmaktadır. Ancak kendisi bu çalışmalarında başarısız olmuş ve bu uğraşın güçlükleri hakkında yazılar yazmıştır.[85, 86]

Yapay zekanın tam anlamıyla ortaya çıkması ise İkinci Dünya Savaşı sıralarında ilk bilgisayarı bulan ve savaşın gidişatını değiştiren Alan Turing tarafından olmuştur. Alan Turing, makine zekası görüşünü ve makinenin insan gibi düşünebilmesini ilk olarak ortaya koyan insandır. Turing testinin mimarı olan Turing, şayet bir insan etkileşim

esnasında insan-bilgisayar arasındaki ayrımı fark edemiyorsa o halde bilgisayarı insan kadar akıllı saymak gerektiği yönündeki varsayımı öne sürmüştür.[85, 87] Şekil 2.1.'de Turing testi gösterilmiştir.

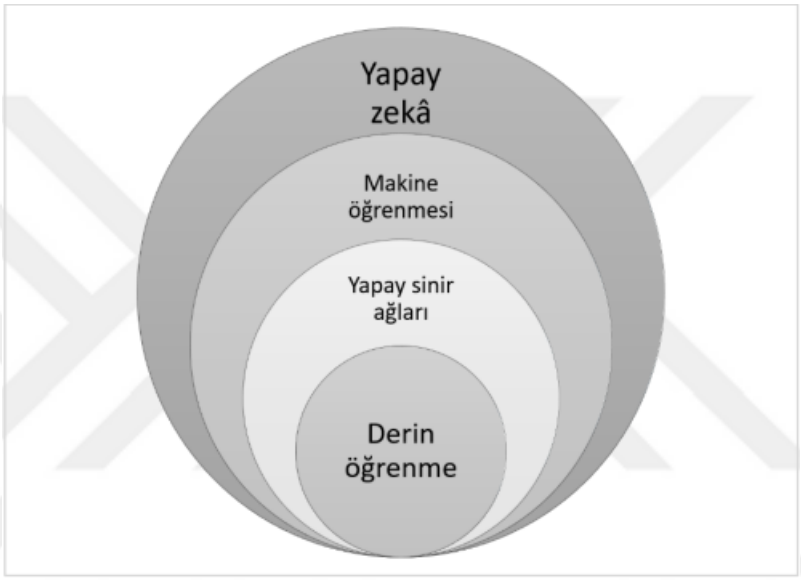


Şekil 2.1. Turing testi[88]

1956 yılında McCarthy "yapay zekâ" terimini ilk ortaya atan kişidir. İsim babası olarak kabul edilen McCarthy yapay zekayı "insan benzeri zeki makineler özellikle zeki bilgisayar programları oluşturma bilimi ve mühendisliği" olarak açıklamıştır.[89] Buna ek olarak McCarthy 1958 yılında "Lisp" adı konan programlama dilini bulmuş ve de ilk kullanımlarda bu dil tercih edilmiştir. 1974-1980 arası ve 1987-1993 arası iki dönemde çok bir ilerleme kaydedilememiş ve özellikle bir 'bilim kurgu unsuru' olarak kalınmıştır. 1993 sonrası gelişim giderek artmıştır, bunun sebebi olarak makinelerin işlem gücündeki ilerlemeler, maliyetlerin düşürülmesi ve daha fazla kişiye ulaşılması sayılabilir. 1997 yılında IBM şirketinin geliştirdiği "Deep Blue" isimli bilgisayarın düzenlenen satranç yarışmasında Gary Kasparov' u yenmesiyle tüm dünyada daha da tanınır hale gelmiştir. Şimdilerde yapay zeka insan bilişsel yetilerini taklit edebilen herhangi bir makineyi veya teknolojiyi belirtmektedir.[17] Yapay zekânın çok sayıda değişik uygulama alanı olmasına ek, bu uygulama alanlarına özel olarak cevap verebilmesi için geliştirilmiş farklı yapay zekâ yöntemleri bulunmaktadır. Makine öğrenmesi, yapay sinir ağları, karmaşık

sistemler, karar ağacı, genetik algoritmalar değişik yapay zekâ sistemlerine örnek olarak verilebilir.

1950’ lerde yapay zeka teriminin ardından 1980’ lerde“ makine öğrenimi“ kavramı ortaya çıkmış bunu “yapay sinir ağları“ ve“ derin öğrenme“ kavramları izlemiştir (Şekil 2.2.).[17]



Şekil 2.2. Yapay zekâyı oluşturan temel kavramlar[17]

2.10. Makine Öğrenmesi (Machine Learning, ML)

Makine öğrenmesi makinelerin, belli algoritmalar ve istatistiksel örnekler kullanarak, örüntüleri tanıyarak, yüklenen bilgiler aracılığıyla insan etkisi olmadan sorunu çözmesidir.[17] Verilerden tecrübe kazanır ve bundan dolayı insan zekasına benzetilmektedir. Makine öğrenmesi algoritmaları ne denli çok veriye maruz kalırsa bir o kadar fazla gelişir ve bunun sonucunda değerlendirme yeteneğini artırarak daha özel yanıtlar vermeyi öğrenir.[90] Makine öğrenmesi insan beyninin birbiri peşi sıra farklı girdiler işleyerek, görüntüleri belirlemesini, öğrenmesini, ayrıştırmasını, alt gruplara ayırmasını, kendi kendini düzeltmesini esas tutan bir tekniktir.[91] Makine öğrenmesi,

öğrenme adımına müdahalede bulunulup bulunulmamasına göre "denetimli" ve "denetimsiz" olarak ikiye ayrılır.

Denetimli öğrenmede her bir veri programlayan kişi tarafından etiketlenir. Verilerin doğru değerlendirilip değerlendirilmemesi çıkan sonucu etkiler. Kişiler tarafından yapılan hatalı etiketleme tarafsız bir sonuca ulaşılmasını engeller.[92] Makine daha sonraları önceden karşılaşmadığı veriler ile bağlantılı eski deneyimlerine dayanarak bir analiz yapar. Burada makineye verilen görevler çoğunlukla insanlar tarafından neredeyse hatasıza yakın bir şekilde yapılmaktadır. Bundan dolayı denetimli öğrenme modeli insan başarısına ulaşmayı hedefler.

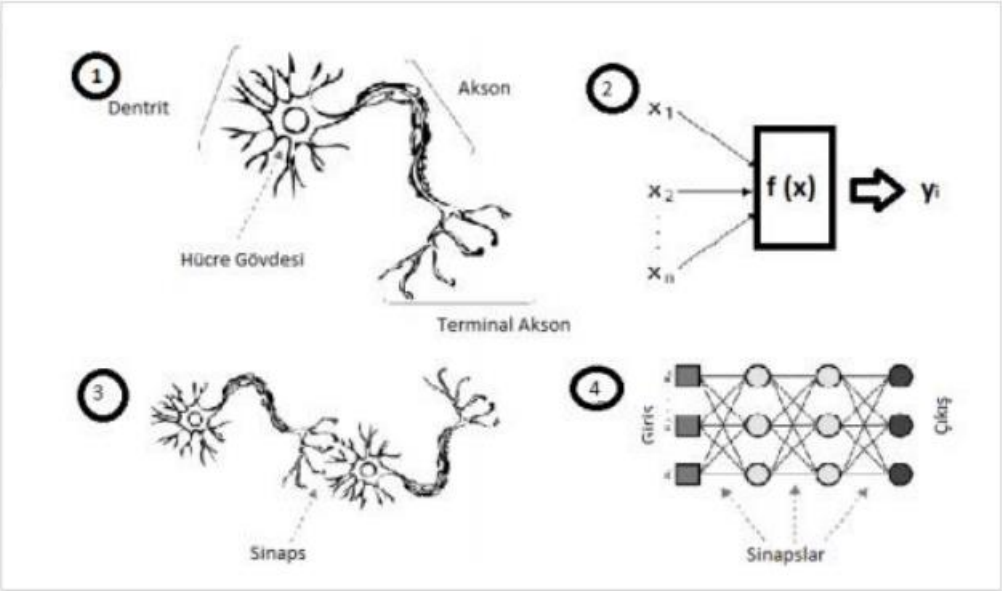
Denetimsiz öğrenmede veriler üzerinde bir etiketleme veya sınıflandırma yapılmamaktadır. Makine verilerdeki modelleri kendi kavramaya çalışır.

2.11. Yapay Sinir Ağları (Artificial Neural Networks-ANN)

1949 yılında Nörolog Donald Hebb yaptığı incelemelerde sinir ağı kuramını bulmuştur. Donald Hebb' e göre yapay sinir ağları biyolojik sinir ağlarına benzeyen bilgisayar programlarıdır.[93, 94]

Yapay sinir ağları son zamanlarda en sık kullanılan makine öğrenme modellerinden biridir. Yapay sinir ağları insanın veya başka canlıların öğrenmesiyle alakalı dış gözlemlerden farklı olarak doğrudan beyin içinde hücresel bağlamdaki çalışma mekanizmalarını taklit ederek geliştirilmiştir. O denli ki yapay sinir ağlarında nöronlar arasındaki bağlantılara ait çok sayıda kavramın karşılığı bulunmaktadır.[95]

Şekil 2.3.’ te biyolojik bir sinir hücresi ve yapay sinir ağının gösterimleri eklenmiştir. Tablo 2.1.’ de ise biyolojik sinir hücresi ve yapay sinir ağının terimsel kıyaslaması verilmiştir.



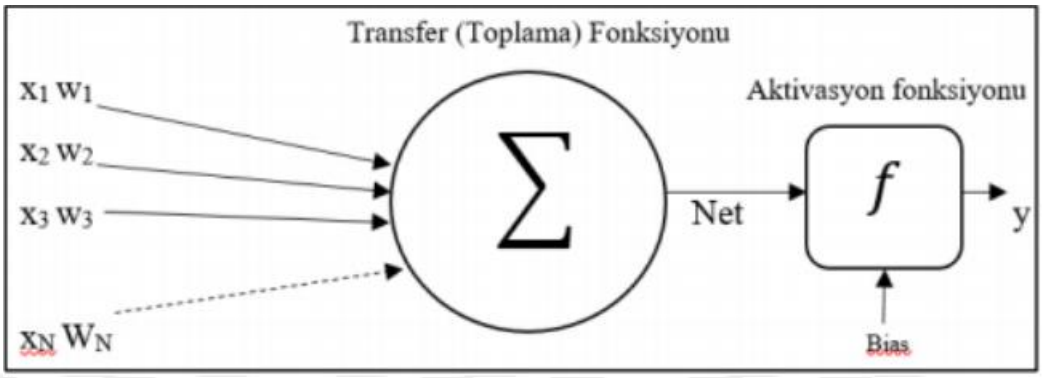
Şekil 2.3. Biyolojik sinir hücresi ve yapay sinir ağı[96]

Tablo 2.1. Biyolojik sinir hücresi ve yapay sinir ağı terminolojisi[86]

Biyolojik Sinir Sistemi	**Yapay Sinir Sistemi**
Nöron	İşlemci Elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Taklit edilen sinir hücreleri benzeri çeşitli katmanlar, farklı biçimlerde birleştirilerek yapay bir sinir ağı meydana getirilir. Veriler oluşturulan bu sinir ağından geçirilir. Yapay bir nöron hücresine n adet veri girişi olmaktadır (x1, x2, x3…..xN). Bu

veri girdilerine cevap olarak ağırlık değerleri (w1, w2, w3….wN) ağ üzerindeki etki değerleridir. Tüm girilen veriler ağırlık değerleri ile çarpılarak transfer fonksiyonuyla birleştirilip aktivasyon fonksiyonundan geçmektedir (Şekil 2.4.).[97]



Şekil 2.4. Yapay sinir ağı nöron modeli[97]

Aktivasyon fonksiyonundan sağlanan değer çıkış değeri olarak bildirilmektedir. Birden fazla girdisi olmasına karşılık yapay sinir hücresinin tek bir çıktı değeri olmaktadır.[98]

Bir yapay sinir ağı ana üç tabakadan oluşmaktadır; girdi katmanı, ara katman ve çıktı katmanı.[99] Kimi kaynaklarda ara katmana gizli katman da denmektedir. Girdi katmanı alınan veriyi ara katmana aktarmaktadır. Ara katman miktarı istenen modele göre farklılık gösterebilir ve temel olarak ağırlık katsayısı verilen katmanlar bu ara katmanlardır. Beklenen sonuç da çıktı katmanı ile alınır. İlk önce katsayı, ara katmanlara seçilmeden atanır. Öğrenme sonrası daha önceden kullanılmamış yeni bir veri grubu kullanılarak sağlama yapılır ve ardından yapay sinir ağları kullanıma hazırdır.[100]

2.11.1. Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağlarının çeşitli temel özellikleri vardır:[86]

• Doğrusal olmama

• Paralel çalışma

• Öğrenme

• Genelleme

• Hata toleransı ve esneklik

• Eksik verilerle çalışma

• Çok sayıda değişken ve parametre kullanma

• Uyarlanabilirlik

Yapay sinir ağları en fazla olarak örnekleri tanıma ve tahminde bulunmada kullanılmaktadır. Ayrıca sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme benzeri işlemlerde de yapay sinir ağlarından yararlanılmaktadır.[101]

Tahmin: Kullanılan yapay sinir ağının, girdi değerlerinden çıktı hakkında tahminde bulunması olarak tanımlanmaktadır.

Veri filtreleme: Bu amaçla eğitilen yapay sinir ağının, çok sayıda veri arasından en çok kullanılacak olan verileri belirlemesi olarak açıklanmaktadır.

Veri ilişkilendirme: Yapay sinir ağının daha önceden öğrendiği bilgileri şimdikilerle ilişkilendirmesi ve yetersiz olan bilgileri tamamlaması olarak belirtilmektedir.

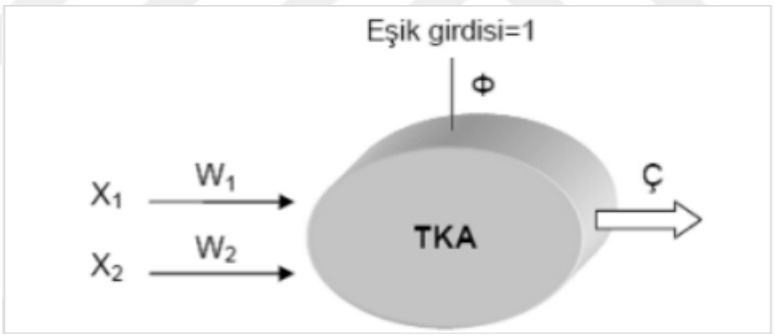
Veri yorumlama: Yapay sinir ağının daha önceden edinilmiş bilgileri analiz ederek yeni durumları yorumlaması olarak ifade edilmektedir.[86]

2.11.2. Yapay Sinir Ağı Modelleri

Yapay sinir ağı modelleri tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olmak üzere dört ayrı grup altında ele alınmaktadır.[86]

2.11.2.1. Tek Katmanlı Algılayıcılar

Tek katmanlı yapay sinir ağları yalnızca girdi ve çıktıdan oluşmaktadır. 1958 senesinde Frank Rosenblatt tarafından 'perceptron' örneklemesi yapılmıştır. Perceptron modelinde birden çok temel girdi alınarak bir çıktı oluşturulur. Bu algılayıcılarda çıktı fonksiyonu doğrusaldır (Şekil 2.5.).[86]

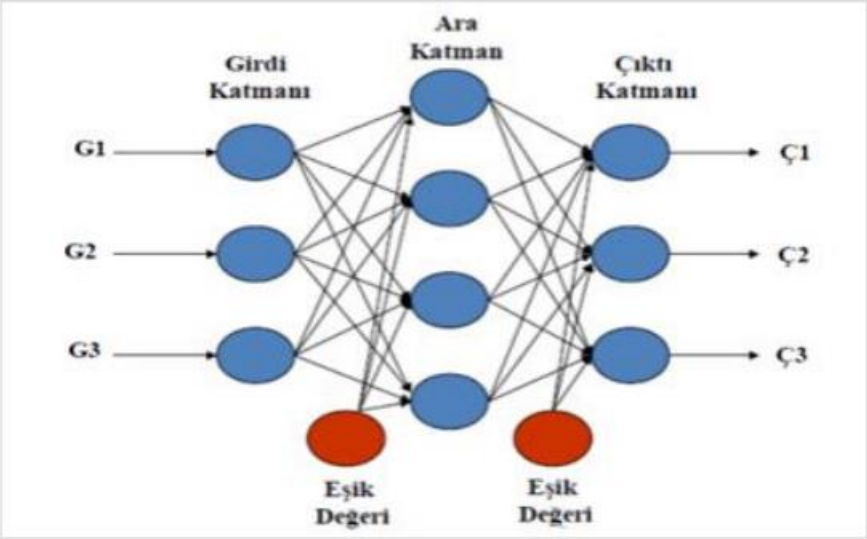


Şekil 2.5. Tek katmanlı algılayıcı modeli[98]

2.11.2.2. Çok Katmanlı Algılayıcılar

Doğrusal olmayan problemlerin çözümünde tek katmanlı algılayıcıların başarılı olamamaları sebebiyle çok katmanlı algılayıcılar geliştirilmiştir. Bu ağlar bilgi girişinin olduğu girdi katmanı, bir veya daha çok gizli (ara) katman ve çıktı katmanından oluşmaktadır. Çok katmanlı algılayıcılar; doğrusal olmayan aktivasyon fonksiyonu olan

çok sayıda nöronun karşılıklı olarak bağlandıkları yapılar olarak tanımlanmaktadır (Şekil 2.6.).[86]

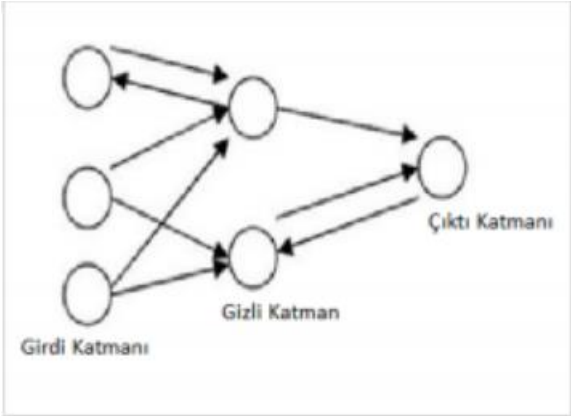


Şekil 2.6. Çok katmanlı algılayıcı model[102]

2.11.2.3. İleri Beslemeli Yapay Sinir Ağları

Veriler tek yönlüdür ve girdi katmanından çıktı katmanına doğru ilerlemektedirler, arada gizli katman vardır. Girdi ve çıktı katmanı tek olmasına rağmen gizli katman sayısı değişiklik göstermektedir. Verinin girdi katmanına girişinin ardından ağırlıkları ile çarpılarak ara (gizli) katmana transferi gerçekleşir. Gizli katmandaki veriler de aynı şekilde ağırlıklar ile çarpılarak gönderildiği çıktı katmanından dış ortama aktarılır.[103, 104]

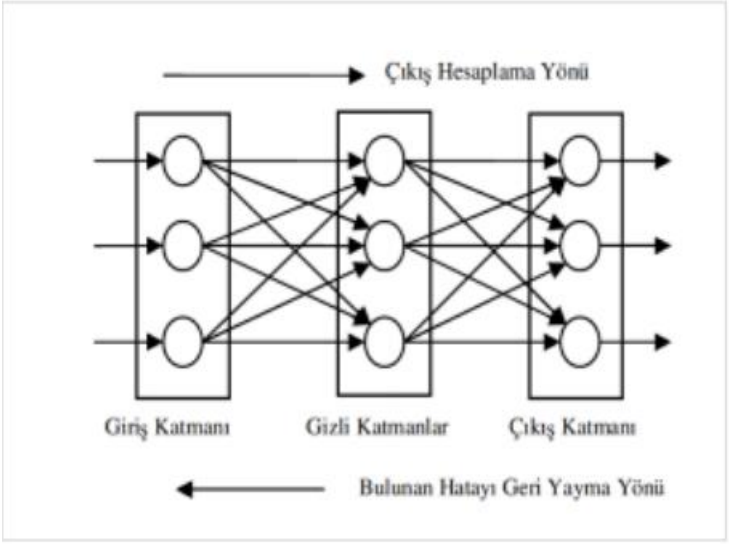
Bu ağda nöronlar katmanlar şeklindedir ve bir katmandan sonra yalnızca kendinden sonraki katmanlara gidecek bağ bulunmaktadır. Bir önceki katmana ya da aynı katmandaki sinir ağları arasında bağlantı yani geri besleme durumu yoktur (Şekil 2.7.). İşlemlerde yapay sinir ağı modellerinden çoğunlukla ileri beslemeli ağlar tercih edilmektedir.[86, 100, 105]



Şekil 2.7. İleri beslemeli ağ yapısı[86]

2.11.2.4. Geri Beslemeli Yapay Sinir Ağları

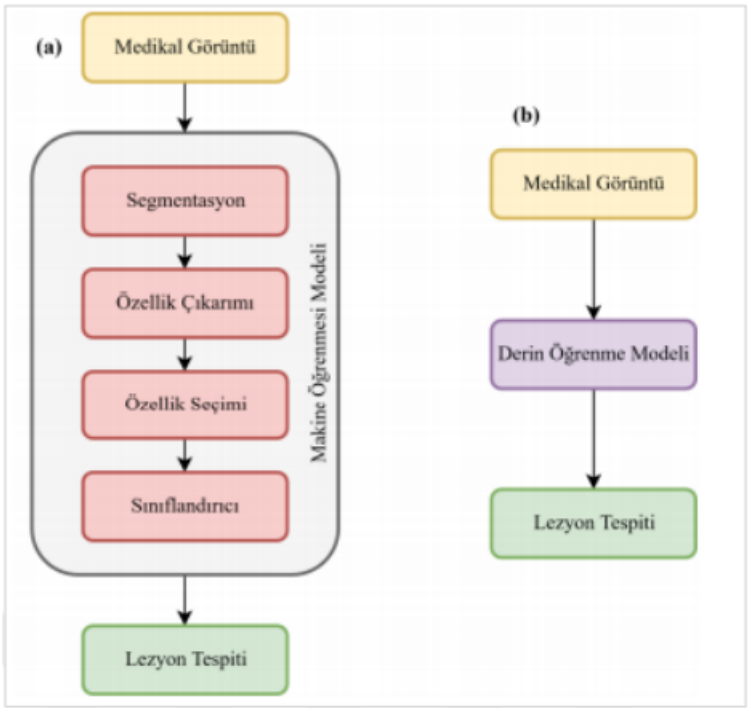
İleri beslemeli ağlar gibi veriler tek yönlü değildir. Veri akışı ileri yönlü olabildiği gibi geriye doğru da olabilmektedir (Şekil 2.8). Geri besleme aynı ya da farklı katmanlardaki hücreler arasında olabileceği gibi nöronlar arasında da olabilmektedir. Geri yayılım safhasında oluşabilecek hata olasılığının azaltılabilmesi için katmanlar arası bağlantı ağırlık değerleri ayarlanır. Bu ağ modeli, istenen davranışa ulaşılabilmek için ayarlanabilen yani eğitilebilen dinamik bir modeldir.[86, 105]



Şekil 2.8. Geri beslemeli ağ yapısı[86]

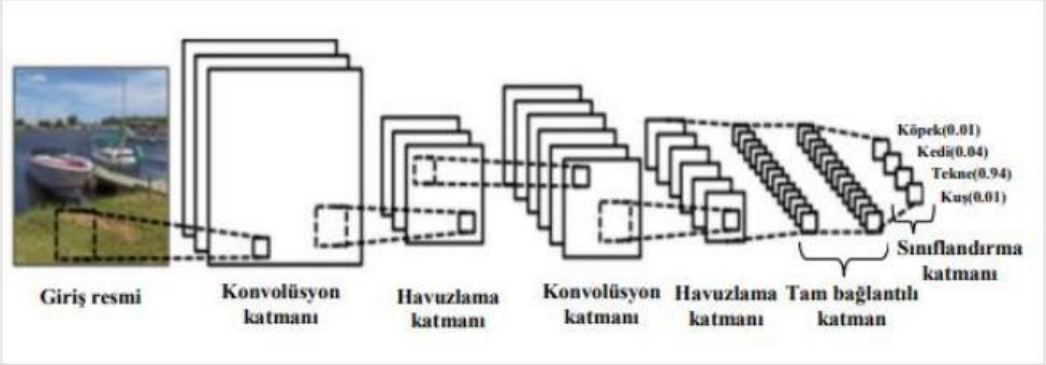
2.12. Derin Öğrenme ve Derin Evrişimli Sinir Ağları (DCNN)

"Derin öğrenme" tanımı ilk olarak 1986' da Rina Dechter tarafından makine öğrenimi zümresine tanıtılmış ve 2000 yılında Igor Aizenberg ve arkadaşları tarafından yapay sinir ağları bağlamında tanımlanmıştır.[106] Makine öğrenmesinin bir alt dalıdır ve daha karmaşık şeklidir. İnsan beyninden esinlenerek oluşturulan çoklu gizli katmanların yer aldığı yapay sinir ağı modellerine dayanmaktadır. Görüntü işlenmesinin yapıldığı yapay zeka sistemlerinin bir haylisinin alt yapısını oluşturmaktadır.[107] Bu modelde sınıflandırılmamış, işlenmemiş ya da etiketlenmemiş verilerden denetimsiz olarak öğrenebilen ağlar mevcuttur. Yani derin öğrenme modelinde ön-işleme aşaması olmadan sınıflandırma yapılabilmektedir. Diğer makine öğrenmesi modellerinden farklı olarak, eğitim süreci sonunda yalnızca ham veriyi işleyerek yorum yapabilme özelliğine sahiptir. Çoğunlukla belirli olmayan veya karmaşık nesneler için oluşan hatalı özellik hesaplaması ve segmentasyon sebebiyle görülen hataların önüne geçebilmektedir (Şekil 2.9.).[108]



Şekil 2.9. a) Makine öğrenmesi, b) Derin öğrenme[109]

Derin öğrenme yapay zekanın en son sürümüdür. Derin öğrenme yönteminde çok katmanlı derin sinir ağları kullanıldığından bu model daha kompleks problemleri halledebilecek yetenektedir.[110] Katman sayısı yönünden diğer yapay sinir ağlarından farklıdır, bu katmanlar yardımıyla girdilerden veri toplamaktadır.[111] Bu fazlasıyla katman içeren ağ oluşumları derin DCNN olarak adlandırılmaktadır (Şekil 2.10.). Katmanlarından çok sayıda özelliği çıkarabilen bu oluşumlar, asıl olarak daha büyük ve kompleks görüntüleri işlemek amacıyla kullanılmaktadırlar.[112] Çeşitli işlemlerde görev alan bu katmanlar medikal görüntülerde; hastalık tespit etmede, sınıflandırmada, nesne tanımlamada kullanılmaktadırlar.[97]



Şekil 2.10. DCNN mimarisi[113]

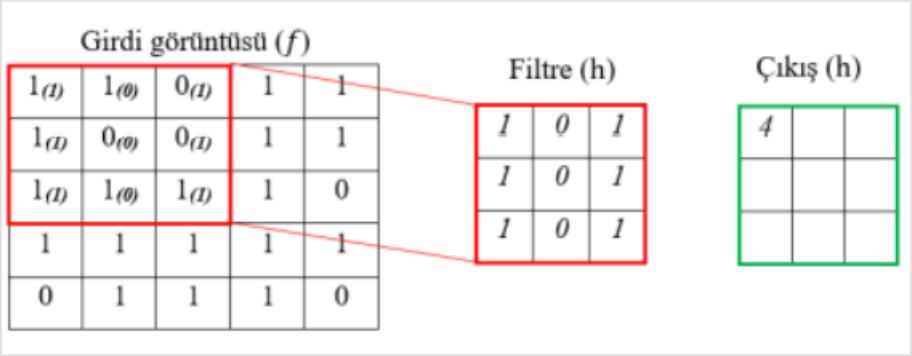
2.13. Evrişimli Sinir Ağı Katmanları

2.13.1. Giriş Katmanı

DCNN' ye ham şekilde verilen giriş görüntüsünü tanımlamaktadır.[97]

2.13.2. Evrişim Katmanı (Konvolüsyon Katmanı)

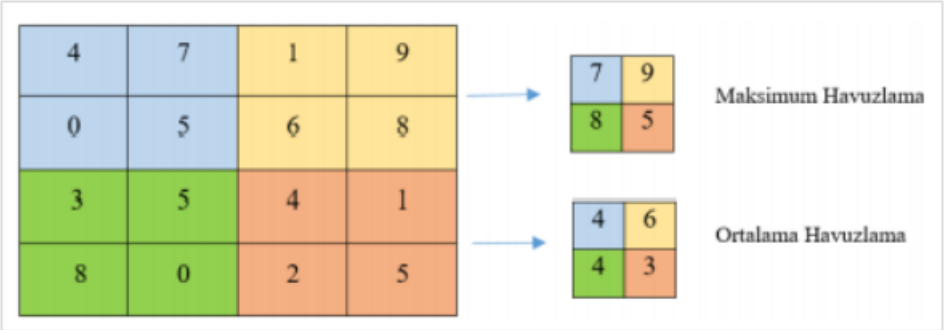
Bu katman girdiyi filtreler vasıtasıyla özellik çıkararak yoğunlaştırdığı katmanı ifade etmektedir. İlk evrişim katmanında belli başlı temel özellikler nöronlar tarafından tespit edilirken, diğer katmanlara gidildikçe daha üst düzey ve karmaşık özellikler saptanır (Şekil 2.11).[114]



Şekil 2.11. Evrişim işlemi[97]

2.13.3. Havuzlama Katmanı

Havuzlama ya da alt örnekleme, genel havuz yaratma, örtüşen havuz yaratma vb. gibi değişik işlemleri kapsamaktadır. Evrişim katmanında oluşturulan çok sayıdaki parametrenin özetlenmesi işlemi yapılmaktadır. Havuzlama, yerel bilgileri bir havuzlama penceresiyle yoğunlaştırarak tek bir değer şeklinde açıklamayı amaçlamaktadır. Bu sırada veri boyutunun küçültülmesi de hesaplamaların azaltılmasına olanak sağlamaktadır (Şekil 2.12.).[97, 115]



Şekil 2.12. Havuzlama örneği[97]

2.13.4. Tam Bağlı Katman

Sıklıkla havuzlama katmanı ardından gelen bu katman, kendinden önce bulunan tüm katmanın bütün alanlarına bağlıdır bundan dolayı tam bağlantılı katman şeklinde isimlendirilmektedir.[116]

2.13.5. Sınıflandırma Katmanı

Tam bağlı katman ardından gelen bu katmanda sınıflandırma işlemi yapılmaktadır. Bu katman sonundaki çıkan değer sınıflandırılması yapılacak olan nesne sayısına eşittir.[116]

2.14. Evrişimli Sinir Ağlarının Eğitilmesi

Öncelikle evrişimsel sinir ağı modeli oluşturulmaktadır. Modeldeki evrişim katmanı, havuzlama katmanı, tam bağlantılı katman ve sınıflandırma katman sayısı saptanmaktadır. Ardından bu katmanların sıralaması oluşturulmaktadır. Bir sonraki adımda değişkenler tanımlanmaktadır (filtre boyutları ve sayısı, adım kayma miktarı).

Oluşturulan modele eğitim setinden bir görüntü verilerek işleme devem edilmektedir. Bu görüntüden sonuca ulaşmak amacıyla sinir ağındaki katmanlardan geçirilmektedir. Devamında ileri besleme ile her katmanda her bir filtrenin ağırlıkları ile görüntüdeki piksel değerleri çarpılarak ardından gelen katmana aktarılmaktadır. Hedeflenen sonuçlar ve üretilmiş olan sonuçların farkı alınarak hata değeri oluşturulmakta ve bu değer ağdaki tüm ağırlıklara dağıtılmaktadır.[116]

2.15. Aktivasyon Fonksiyonu

Sinir ağlarında giriş değerleri ağırlık değerleri ile çarpılır ardından transfer fonksiyonuyla birleştirilip aktivasyon fonksiyonundan geçirilerek bir çıktı elde edilmektedir. Aktivasyon fonksiyonları sinir ağlarında doğrusal olan ifadeleri doğrusal olmayan ifadelere dönüştürmeyi sağlayarak ağın eğrisel fonksiyonları da öğrenebilmesini amaçlarlar. Bu fonksiyonlar sinir ağlarının öğrenme gelişimini etkilemektedirler.[97, 117]

2.16. Transfer Öğrenme

Derin evrişimli sinir ağları eğitiminde en büyük sorun veri setinin yetersiz olduğu durumlardır. Transfer öğrenme; bunun benzeri durumlarda önceden eğitilmiş bir CNN modelini, amaçlanan göreve göre değiştirerek, hedef veri kümesi üzerinde ince ayar yapılmasına yarayacak olan parametrelerin aktarılması olayıdır. Bu DCNN modellerine AlexNet, VGGNet, GoogleNet ve ResNet mimarileri örnek olarak verilebilir.[97]

2.17. Diş Hekimliğinde Yapay Zekâ ve Kullanım Alanları

Son zamanlarda yapay zeka uygulamaları diş hekimliğinin birçok dalı için popüler hale gelmeye başlamıştır. Yapay zeka diş hekimliğinde, asıl olarak yüksek kalitede hasta bakımı ile beraber, uygulanan tedavilerde olabilecek en iyi sonuçların sağlanmasında büyük rol oynayan tanı sürecini mümkün olabildiğince en doğru hale getirmek amacıyla kullanılmaktadır. Yapay zekanın diş hekimlerinin hayatına girmesiyle birlikte insan kaynaklı hataları azaltıp zamandan ve maliyetten kazanç sağlaması amaçlanmaktadır. Diş hekimlerinin doğru bir karara ulaşmak için sıkıntı yaşadıkları durumlarda daha başarılı kararlar alabilmeleri için onları yönlendirici bir sistemdir.[16, 17]

Diş hekimliği radyolojisinde; diş tespit ve sınıflandırmasında, diş eksikliğinin belirlenmesinde, fazladan kök ve süpernümerer diş tespitinde, vertikal kök kırığı saptanmasında, ağız kokusunun tespitinde, apikal lezyonun belirlenmesinde, çene kisti ve tümörü tespitinde, Sjögren sendromu tespitinde, osteoporoz teşhisi konulmasında, ultrasonografi uygulamalarında evrişimli sinir ağlarından yararlanılmıştır.[118-120]

Restoratif diş hekimliğinde; çürük lezyonu tespitinde yapay zeka modellerinden faydalanılmaktadır. Yapılan bazı çalışmalarda derin öğrenme yöntemiyle yapılan çürük tespitinin diş hekimlerine oranla daha fazla başarı gösterdiği görülmüştür. Çürük tespitine ek olarak beyaz nokta lezyonlarının belirlenmesinde de yapay zeka modelleri kullanılmaktadır.[121, 122]

Ağız, diş, çene cerrahisinde; anatomik yapıların belirlenmesinde yapay zeka modellerinden faydalanılmaktadır, bu vesileyle operasyon sırasında anatomik yapılar korunmuş olur.[123, 124] geliştirilen modelin Gömülü üçüncü molar dişlerin belirlenmesinde, komşu anatomik yapılarla olan ilişkilerinin değerlendirilmesinde ve çekim zorluğu açısından değerlendirilmesinde yapay zeka modelleri kullanılmaktadır.[125, 126]

Periodontoloji alanında; alveoler kemik kaybının belirlenmesinde, implant planlamasında, peri-implantitis saptanmasında, periodontal hastalık nedeniyle prognozu iyi olmayan dişlerin tespitinde derin öğrenme yöntemlerinden yararlanılmaktadır.[127-129]

2.17.1. Ortodonti Alanında Yapay Zekâ

Ortodontide; tanı tedavi protokollerinde, büyüme gelişim döneminin tespit edilmesinde, anatomik noktaların belirlenmesinde, iskeletsel sınıflandırmada, çekimli-çekimsiz tedavi seçiminde ve ortognatik cerrahi gibi çok sayıda alanda yapay zeka modellerinden yararlanılmaktadır.[18, 19]

Son yıllarda anatomik noktaların belirlenmesinde derin öğrenme yöntemleri oldukça yarar sağlamaktadır. Yu ve ark.[130] evrişimli sinir ağını kullanarak yaptıkları çalışmada başarılı bir iskeletsel tanı sistemini oluşturmayı hedeflemişlerdir. Bu çalışmada elde edilen sonucun başarılı bulunduğu, %90 oranında duyarlılık, doğruluk ve özgüllük gösterdiği çıkarımında bulunulmuştur.

Kök ve ark.[19] yapay zeka algoritmalarını kullanarak yaptıkları çalışmada servikal vertebra evrelerini inceleyerek büyüme ve gelişim döneminin hangi evresinde olunduğunun tespitini yapmışlardır. Yapay zeka modellerinin, büyüme gelişiminin tespit edilmesi gereken tüm bilim dallarında teşhis için kullanılabileceği ve böylelikle daha doğru bir tedavi planı oluşturulmasına yardımcı oldukları bildirilmiştir.

Xie ve ark.[18] yapay zeka modelleri ile ortodontik tedaviye başlamadan diş çekiminin gerekip gerekmediğini değerlendirmişlerdir ve %80 oranında bir doğruluk payı elde edildiğini tespit etmişlerdir.

Choi ve ark.[131] geliştirdikleri yapay zeka modelleri ile ortodontik tedavi uygulanacak hastalara ortognatik cerrahi gerekip gerekmediğini değerlendirmişlerdir ve ortaya çıkan sonuç oldukça başarılı bulunmuştur. Ortognatik cerrahi öncesi planlama yapılırken de bu algoritmalardan faydalanılmaktadır.

3. MATERYAL VE METOT

3.1. Hasta Seçimi

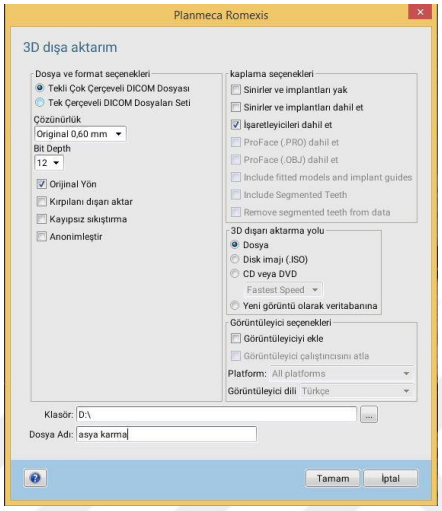
Bu çalışmada ortodontik tedavi amacıyla Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalına başvuran hastaların KIBT verilerinden elde edilen sefalometrik radyografik görüntüler kullanıldı. Veri seti Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı radyografi arşivinden Ocak 2013-Eylül 2021 tarihleri arasında alınmış karma veya daimi dişlenme dönemindeki 1295 hastanın KIBT görüntü kayıtlarından oluşmaktadır. Görüntü kalitesi kötü olan radyografik görüntüleri bulunan (metal artefaktı, çekim sırasında oluşan pozisyon hataları kaynaklı artefaktlar vb. sebeplerle meydana gelen bozukluklar), kraniyofasiyal sendromu, dudak damak yarığı olan, herhangi bir travmaya bağlı yüz deformitesine sahip hastaların radyografik görüntüleri çalışmaya dâhil edilmedi.

Çalışma protokolü Eskişehir Osmangazi Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Komitesi tarafından onaylandı (karar tarihi ve numarası: 26.10.2021/53). Çalışma Helsinki Bildirgesi' nin ilkelerine göre yapıldı.

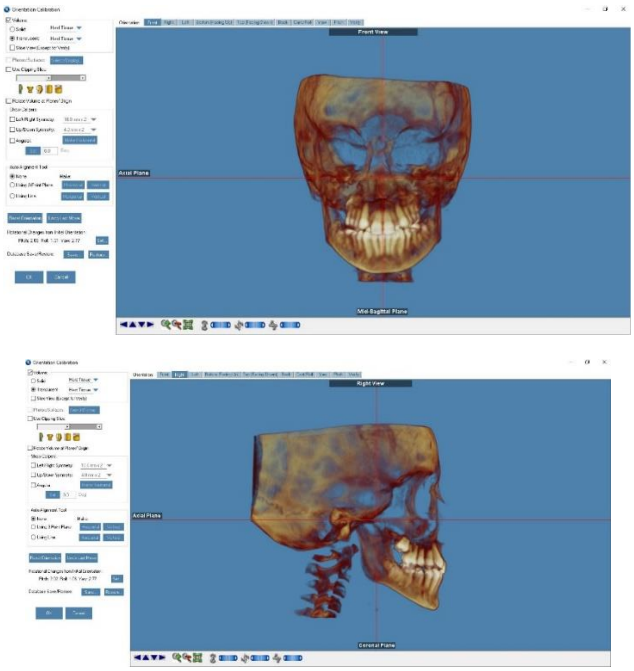
3.2. Radyografik Veri Setinin Elde Edilmesi

Arşivdeki tüm görüntüler aynı KIBT cihazı (Promax 3D Mid; Planmeca, Helsinki, Finlandiya) kullanılarak elde edildi. Görüntüleme parametreleri: tüp voltajı 94 kVp, X ışını tüp akımı 14 mA(miliamper) , 360° dönme, tarama süresi 27 sn ve voksel boyutu 0.600 mm’ dir. KIBT görüntüleri Digital Imaging and Communication in Medicine (DICOM) dosyaları şeklinde kaydedildi. Çalışmada 1295 hastanın KIBT görüntülerinden kaydedilmiş DICOM dosyalarından Dolphin Imaging 11.95 software (Dolphin Imaging

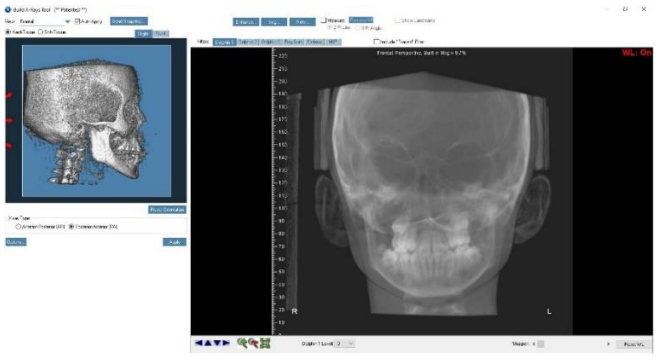
and Management Solutions, Chatsworth, Calif) yazılımı kullanılarak baş pozisyonu Frankfort Horizontal düzlemi yere paralel olacak şekilde ayarlanıp daha sonrasında sefalometrik radyograflar oluşturuldu. Elde edilen sefalometrik radyograflar CranioCatch etiketleme yazılımına (Eskişehir, Türkiye) yüklenerek proje oluşturuldu.



Şekil 3.1. Romexis programından KIBT görüntüsünün dışa aktarımı



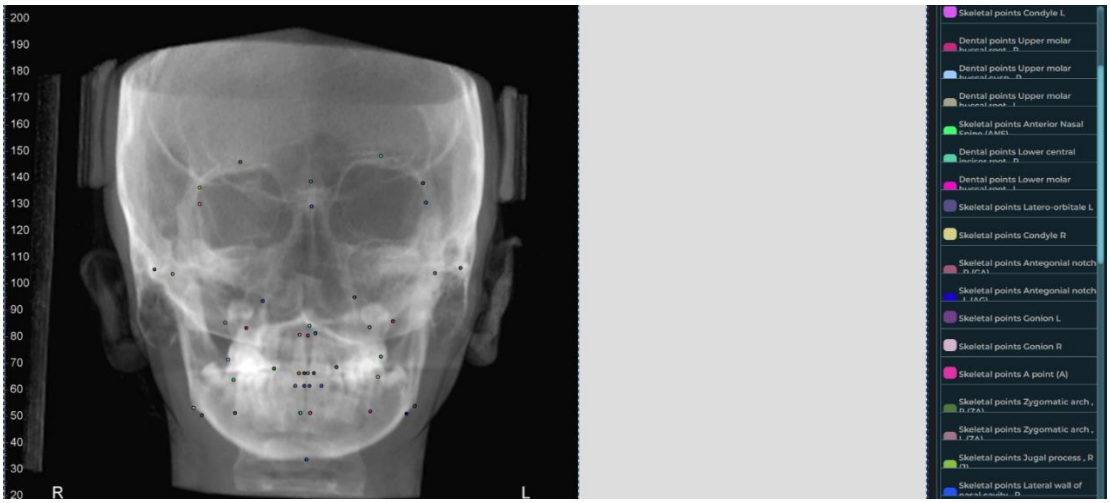
Şekil 3.2. Dolphin Imaging programında baş pozisyonunun ayarlanması



Şekil 3.3. Dolphin Imaging programında sefalometrik radyograf oluşturulması

3.3. Veri Etiketleme

Etiketleme, bir görüntüdeki noktanın tanımlanması ve tanımlanan noktanın hangi referans noktası olduğunun belirlendiği işlemdir. 1295 hastanın KIBT görüntülerinden elde edilen sefalometrik radyograflar CranioCatch programına yüklendi. Sefalometrik radyograf üzerinde belirtilen referans noktalarının etiketlenmesi; 3.5 yıllık deneyime sahip bir araştırma görevlisi ve 11 yıllık deneyime sahip ortodonti uzmanı tarafından CranioCatch (Eskişehir, Türkiye) yazılımı kullanılarak Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Dental Al Laboratuvarı'nda bulunan Precision 3640 Tower CTO BASE workstation (Intel(R) Xeon(R) W-1250P (6 çekirdek, 12 M önbellek, temel işlemci frekansı 4.1 GHz, Maks Turbo Frekansı 4.8 GHz) DDR4-2666, 64 GB DDR4 (4 X16GB) 2666 MHz UDIMM ECC Hafıza kapasitesi, 256 GB SSD SATA, Nvidia Quadro P620, 2 GB) (Dell, Texas, ABD) ve 27", 1920 x 1080 piksel IPS LCD monitör (Dell, Texas, ABD) kullanılarak gerçekleştirildi (Şekil 3.4.).



Şekil 3.4. Sefalometrik noktaların CranioCatch programında etiketlenmesi

3.4. Sefalometrik Radyograflar Üzerinde İşaretlenen Referans Noktalar

Görüntülerin değerlendirilmesi 1920 x 1080 piksel IPS LCD monitör (Dell, Texas, ABD) kullanılarak gerçekleştirildi. Elde edilen sefalometrik radyograflar CranioCatch etiketleme yazılımına (Eskişehir, Türkiye) aktarılarak radyograflar üzerinde iskeletsel ve dental noktalar işaretlenmiştir. Radyografi görüntüleri %150 oranında büyütülerek noktalama işlemleri gerçekleştirilmiştir. Kullanılan noktalar aşağıdaki gibi isimlendirilmekte ve tanımlanmaktadır.

3.4.1. İskeletsel İşaret Noktaları

3.4.1.1. Orta Hattaki İskeletsel Noktalar

Crista Galli (CG): Crista galli’ nin en üst noktası

Nasal Septum (NS): Nasal septum’ un üst görüntüsünün en yukarı noktası

Anterior Nasal Spine (ANS): Nasal septum ve damağın kesişiminin merkezi

A noktası (A): Anterior nasal spina altındaki üst çene ön alveol kemik girintisinin en derin noktası

Menton (Me): Koronal düzlemde simfizin en alt noktası

3.4.1.2. Çift Taraflı İskeletsel Noktalar

Zygomatic Arch (ZAR-ZAL): Zigomatik ark merkezinin en dış yan noktası (sağ ve sol)

Condylar (CdR-CdL): Kondil başının en üst noktası (sağ ve sol)

Latero-orbitale (LoR-LoL): Orbitanın yan duvarı ile sfenoidin büyük kanadının (oblik doğru) kesişim noktası (sağ ve sol)

Lateral Wall of Nasal Cavity (NCR-NCL): Nasal kavitenin en dış yan noktası (sağ ve sol)

Maxillare (MxR-MxL): Maksillanın lateral konturu ile maksillozygomatik çıkıntının alt konturunun kesişim noktası, aynı zamanda lateral maksiller konkavitenin en derin noktası olarak da tanımlanabilir ve Ricketts jugal (J) noktası olarak adlandırır (sağ ve sol)

Gonion (GoR-GoL): Corpus mandibularis alt kenarı ile ramus mandibularis arka kenarının birleşim noktası (sağ ve sol)

Antegonion (AGR-AGL): Antegonial çıkıntının alt kenarının dış yan noktası (sağ ve sol)

Z noktası(ZR-ZL): Fronto-zigomatik suturun iç yan noktası (sağ ve sol)

Supraorbitale (ROR-ROL): Orbita çatısının en üst noktası (sağ ve sol)

3.4.2. Dişsel İşaret Noktaları

3.4.2.1. Çift Taraflı Dişsel Noktalar

Upper Molar Buccal Cusp (U6CR-U6CL): Maksiller birinci moların bukkal kaspı (sağ ve sol)

Upper Molar Buccal Root (U6RR-U6RL): Maksiller birinci moların bukkal kökü (sağ ve sol)

Lower Molar Buccal Cusp (L6CR-L6CL): Mandibular birinci moların bukkal kaspı (sağ ve sol)

Lower Molar Buccal Root (L6RR-L6RL): Mandibular birinci moların bukkal kökü (sağ ve sol)

Lower Cuspid Tip (L3CR-L3CL): Mandibular kaninin kasp tepesi (sağ ve sol)

Upper Central Incisor Tip: Maksiller santral kesici ucu (sağ ve sol)

Upper Central Incisor Root: Maksiller santral kesici kök ucu (sağ ve sol)

Upper Central Incisor Mesial: Maksiller santral kesici mesial ucu (sağ ve sol)

Lower Central Incisor Tip: Mandibular santral kesici ucu (sağ ve sol)

Lower Central Incisor Root: Mandibular santral kesici kök ucu (sağ ve sol)

Lower Central Incisor Mesial: Mandibular santral kesici mesial ucu (sağ ve sol)

3.5. Derin Öğrenme Mimarisi

Yueyuan ve ark.[132] tarafından önerilen özellik toplama ve iyileştirme ağı (FARNet), evrişimli sinir ağı tabanlı bir derin öğrenme modeli olarak sefalometrik noktaların tespitinin geliştirilmesini modellemek için kullanıldı.

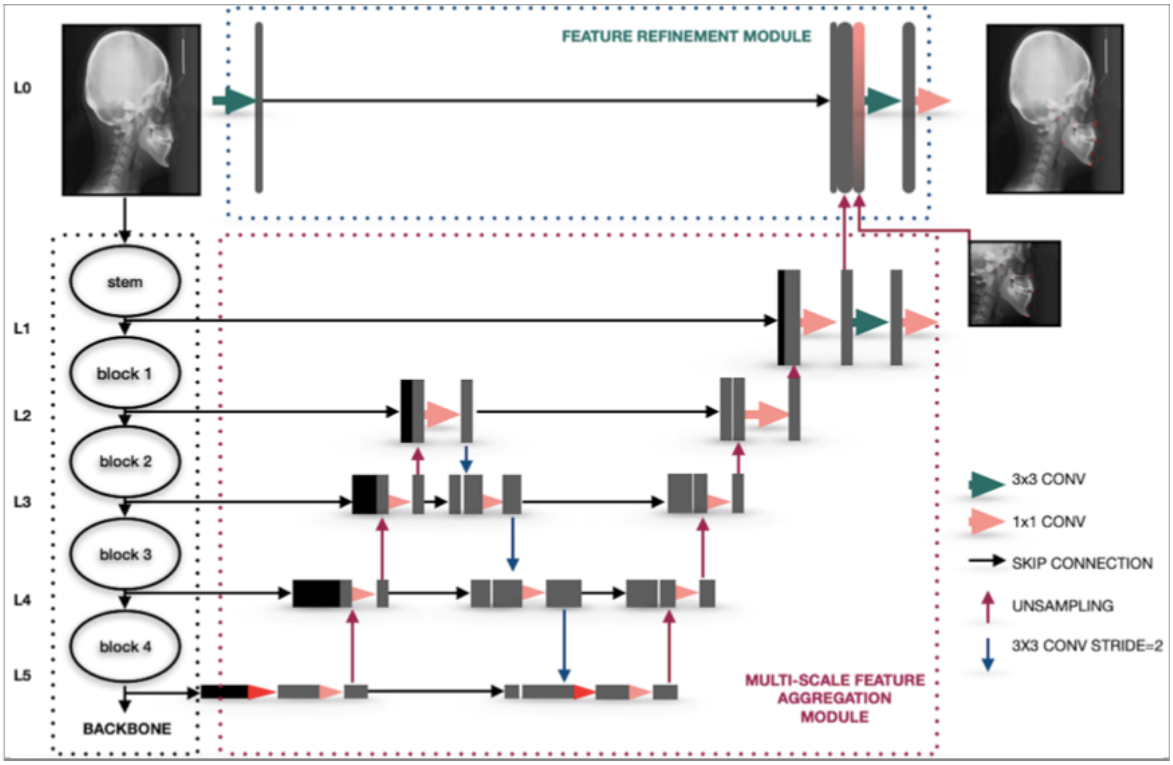
Özellik toplama ve iyileştirme ağı; omurga ağı, çok ölçekli bir özellik toplama ağı (MSFA) ve özellik iyileştirme ağı (FR) dahil olmak üzere 3 ana sistemden oluşur.

Omurga ağı, ImageNet üzerinde eğitilmiş önceden eğitilmiş bir mimaridir.

Omurga ağı, VGG, [133] ResNet [134] veya DenseNet [135] vb. gibi popüler bir ImageNet üzerinden eğitilmiş ağı benimser. Omurga ağı, birden çok ölçekte özellik haritalarından oluşan bir özellik hiyerarşisini hesaplar.

MSFA modülümüz ve FR modülümüz, omurga tarafından çıkarılan çok ölçekli özellikleri birleştirmek ve önemli nokta tahmini için yüksek çözünürlüklü özellik haritaları sağlamak için yukarı örnekleme, aşağı örnekleme özellik toplama yollarını ve yanal bağlantıları benimser (Şekil 3.5.). Her bir özellik füzyon bloğunda, farklı çözünürlüklere sahip özellikler, daha yüksek çözünürlüklü özelliklerin, düşük çözünürlüklü olanlardan daha fazla kanal tutularak vurgulandığı, daha yüksek

çözünürlüklü baskın bağlantı yoluyla birleştirilir. MSFA modülünden elde edilen özellik haritaları, giriş görüntüsü olarak yarı çözünürlüğe sahiptir. Daha doğru bir tahmin elde etmek için, giriş görüntüsündeki ile aynı çözünürlükte özellik haritaları oluşturmak için FR modülü kullanıldı.[132]



Şekil 3.5. Özellik toplama ve iyileştirme ağının (FARNet) mimarisi

FR modülünde, giriş görüntüsü üzerinde 3×3 evrişim katmanı gerçekleştirilir ve sonuç özellik haritaları, MSFA modülünden yukarı örneklenmiş özellik haritaları ve ısı haritaları ile birleştirilir. Birleştirilmiş özellik haritaları, bildiğimiz kadarıyla ilgili çalışmalar arasında kullanılan en yüksek çözünürlük olan giriş görüntüsü aynı çözünürlüğe sahiptir. MSFA modülünden gelen ısı haritaları, daha yüksek çözünürlükte (FR modülü) ısı haritası regresyonuna rehberlik etmek için kullanılır. Son olarak, ısı haritalarını regresyona tabi tutmak için birleştirilmiş öznitelikler üzerinde bir 3×3 evrişim katmanı ve 1x1 evrişim katmanı da gerçekleştirilir. Deneysel doğrulama yoluyla, özellik iyileştirme modülümüz tahminin doğruluğunu etkin bir şekilde artırabilir.[136]

3.6. Model Geliştirilmesi

Model geliştirme süreci, Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Dental-AI Laboratuvarı'nda Precision 3640 Tower CTO BASE iş istasyonu Intel(R) Xeon(R) W-1250P (6 çekirdekli, 12 M önbellek) içeren bilgisayar ekipmanı üzerinde gerçekleştirilmiştir (çekirdek işlemci frekansı 4,1 GHz, Maks Turbo Frekansı 4,8 GHz). DDR4-2666, 64 GB DDR4 (4 X16 GB) 2666 MHz UDIMM ECC bellek kapasitesi, 256 GB SSD SATA, Nvidia Quadro P620, 2 GB) ve NVIDIA Tesla V100 grafik kartı (Dell, Texas, ABD) ve 27", 1920 x 1080 piksel IPS LCD monitör (Dell, Tex, ABD). Python açık kaynaklı programlama dili (v.3.6.1; Python Software Foundation, Wilmington, Del, ABD) ve Pytorch model geliştirme için kütüphane kullanılmış ve 23 iskeletsel nokta ve 22 dişsel nokta etiketli 1295 sefalometrik karışık boyutlu görüntü elde edilmiştir.

3.7. Eğitim Aşaması

Görüntüler ve etiketler 1935 × 2400 olarak yeniden boyutlandırılmıştır. Her nokta için bir satır belirlenmiştir. Etiketler belirtilen sırada 45 nokta olarak txt formatında kaydedilmiştir. Veri setleri eğitim, test ve doğrulama olarak 3 bölüme ayrılmıştır:

Sefalometrik görüntüler herhangi bir ön eğitimden geçirilmeden direkt olarak DL mimarilerinin eğitimi ve testi için kullanılmıştır.

Eğitim veri seti: Modelin eğitimini sağlamak için kullanılan veri setini oluşturmaktadır.[137]

Doğrulama veri seti: Modelin eğitiminden bağımsız olan ve bu süreçte modelin görmemesi gereken örnekleri oluşturmaktadır. [137]

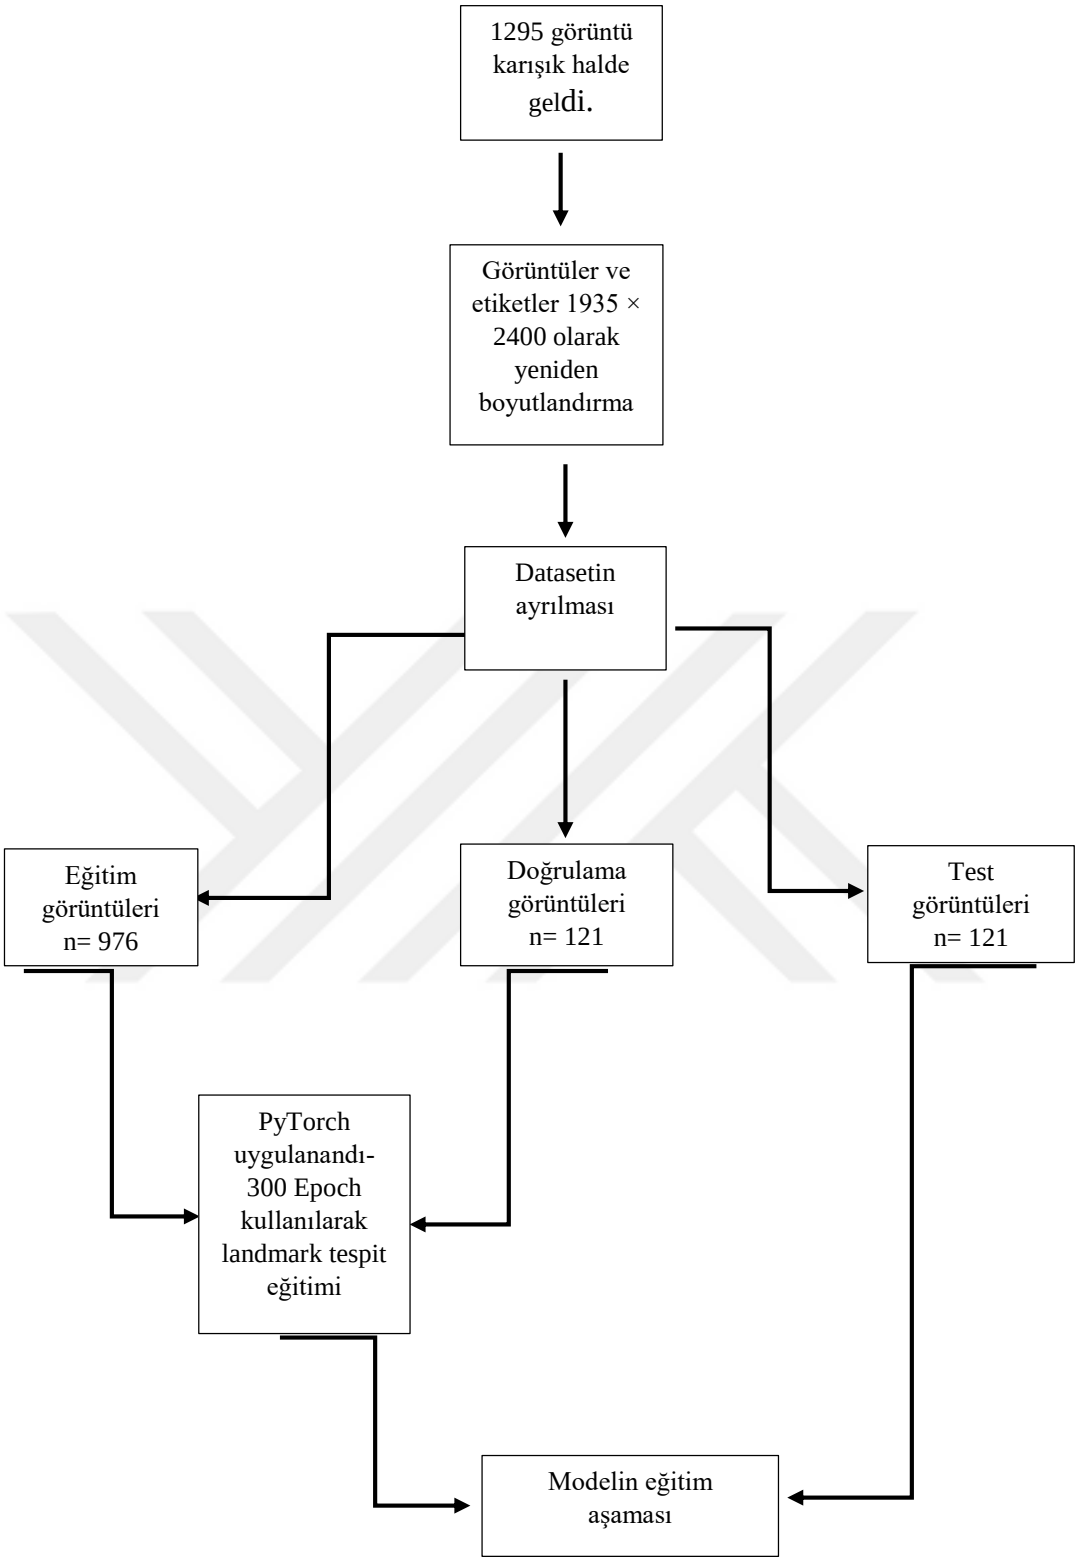
Test veri seti: Eğitim ve doğrulama verileri kullanılarak eğitilen modelin denemesinin yapıldığı veri setini oluşturmaktadır.

Eğitim ve doğrulama veri setleri optimal CNN algoritması ağırlık faktörlerini tahmin etmek ve üretmek için kullanıldı. Test veri setiyle de modellerin başarımlarının değerlendirilmesi yapılmıştır. Veri setinin yaklaşık olarak %10' u test, %10' u doğrulama, %80' i de eğitim veri seti olarak ayrılmıştır.

Tablo 3.1. Veri seti sınıflandırılması

Eğitim Veri Seti	976 Görüntü
Doğrulama Veri Seti	121 Görüntü
Test Veri Seti	121 Görüntü

Test grubundan elde edilen veriler tekrar kullanılmamıştır. AI modelinin eğitimi, PyTorch uygulanan CNN tabanlı derin öğrenme yöntemi ile 300 Epoch kullanılarak gerçekleştirildi. Modelin öğrenme oranı 0.0001 olarak belirlenmiştir.



Şekil 3.6. Farnet mimarisi ile gerçekleştirilen diş tespit modelinin gelişim aşamalarının diyagramı

3.8. Model Performansının Değerlendirilmesi

Her bir landmark için noktadan noktaya hata, mutlak mesafe ile ölçüldü ve tüm test veri seti üzerinden ortalaması alındı. Yer işareti hatası manuel olarak ölçüldü ve sırasıyla bir görüntünün işaret noktası konumu tahmin edildi. Tüm işaret noktaları için Ortalama Radyal Hata (MRE) ve Standart Sapma (SD) değerleri rapor edildi. Yatay (x) ve dikey (y) koordinat sistemlerinde Δx olarak hesaplanan radyal hata (R), x yönünde tahmini konum ile manuel olarak yerleştirilmiş standart konum arasındaki mesafedir ve Δy, tahmini konum ile y yönündeki manuel olarak yerleştirilmiş standart konum arasındaki mesafedir.[136]

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

MRE ve SD, aşağıdaki formül kullanılarak hesaplandı:[136]

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

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

Sırasıyla 2 mm, 2.5 mm, 3 mm ve 4 mm' lik her bir hassasiyet aralığında tahmini noktaların yüzdelerini gösteren başarılı tespit oranları (SDR) ölçülmüştür. Her bir sefalometrik işaret noktası için, AI tarafından otomatik olarak belirlenen konum ile işaretlenen nokta belirli bir d değerinden yüksek değilse, AI tarafından algılanan otomatik lokalizasyon başarılı kabul edilir ve d' nin doğruluğuna ilişkin SDR hesaplanabilir.[136]

4. BULGULAR

Çalışmamızda sefalometrik landmark tespiti için kullanılan derin öğrenme modelinin, KIBT görüntülerinden elde edilen posteroanterior sefalometrik radyograflar üzerinde ortodontik analizlerde kullanılan iskeletsel ve dişsel noktaların tespitinin başarısı araştırılmıştır.

Sunulan AI sistemi (CranioCatch, Eskişehir, Türkiye) bir posteroanterior sefalometrik radyografide 45 anatomik noktayı saptayabilir.

En yüksek SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için Antegonial notch, L (AG), Antegonial notch, R (GA) ve Gonion, L noktalarından sırasıyla 100, 100, 100 ve 100 olarak elde edildi. AGL' nin MRE ± SD değeri 0.60 ± 0.28, AGR' nin MRE ± SD değeri 0.63 ± 0.40 ve GoL' nin MRE ± SD değeri 0.66 ± 0.30 olarak bulundu.

En düşük SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için Crista galli (CG) noktasından sırasıyla 65.2, 71.9, 78.5 ve 85.1 olarak elde edildi. CG' nin MRE ± SD değeri 2.05 ± 1.62 olarak bulundu.

Menton noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 99.1, 100, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.69 ± 0.40 olarak bulundu.

Gonion R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 99.1, 99.1, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.63 ± 0.41 olarak bulundu.

A noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 98.3, 100, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.79 ± 0.46 olarak bulundu.

Upper central incisor root, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 98.3, 100, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.89 ± 0.48 olarak bulundu.

Upper central incisor tip, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 97.5, 98.3, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.79 ± 0.50 olarak bulundu.

Lower central incisor root, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 96.6, 99.1, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.99 ± 0.54 olarak bulundu.

Upper molar buccal cusp, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 96.6, 99.1, 99.1 ve 100 olarak elde edildi. MRE ± SD değeri 0.83 ± 0.55 olarak bulundu.

Upper central incisor mesial, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 96.6, 98.3, 99.1 ve 99.1 olarak elde edildi. MRE ± SD değeri 0.78 ± 0.56 olarak bulundu.

Upper central incisor root, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 96.6, 98.3, 98.3 ve 98.3 olarak elde edildi. MRE ± SD değeri 1.00 ± 0.85 olarak bulundu.

Upper central incisor tip, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 96.6, 98.3, 98.3 ve 98.3 olarak elde edildi. MRE ± SD değeri 0.94 ± 1.42 olarak bulundu.

Supraorbitale L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 95.8, 100, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.95 ± 0.48 olarak bulundu.

Latero-orbitale L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 95.8, 98.3, 99.1 ve 100 olarak elde edildi. MRE ± SD değeri 0.90 ± 0.53 olarak bulundu.

Upper central incisor mesial, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 95.8, 98.3, 98.3 ve 98.3 olarak elde edildi. MRE ± SD değeri 0.92 ± 1.55 olarak bulundu.

Anterior Nasal Spine (ANS) noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 94.2, 99.1, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.90 ± 0.54 olarak bulundu.

Upper molar buccal root, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 94.2, 97.5, 100 ve 100 olarak elde edildi. MRE ± SD değeri 1.11 ± 0.57 olarak bulundu.

Lower molar buccal cusp, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 94.2, 97.5, 98.3 ve 99.1 olarak elde edildi. MRE ± SD değeri 0.91 ± 0.62 olarak bulundu.

Upper molar buccal cusp, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 93.3, 97.5, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.94 ± 0.59 olarak bulundu.

Lower molar buccal cusp, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 93.3, 96.6, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.95 ± 0.59 olarak bulundu.

Lower cuspid tip, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 93.3, 95.0, 97.5 ve 99.1 olarak elde edildi. MRE ± SD değeri 1.03 ± 0.68 olarak bulundu.

Latero-orbitale R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 92.5, 96.6, 100 ve 100 olarak elde edildi. MRE ± SD değeri 0.89 ± 0.61 olarak bulundu.

Lower central incisor root, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 92.5, 98.3, 99.1 ve 99.1 olarak elde edildi. MRE ± SD değeri 1.02 ± 0.64 olarak bulundu.

Zygomatic arch, L (ZA) noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 92.5, 97.5, 98.3 ve 99.1 olarak elde edildi. MRE ± SD değeri 0.93 ± 0.65 olarak bulundu.

Supraorbitale R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 91.7, 98.3, 99.1 ve 100 olarak elde edildi. MRE ± SD değeri 1.01 ± 0.63 olarak bulundu.

Lower central incisor tip, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 91.7, 94.2, 97.5 ve 99.1 olarak elde edildi. MRE ± SD değeri 1.03 ± 0.75 olarak bulundu.

Zygomatic arch, R (ZA) noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 91.7, 95.0, 96.6 ve 98.3 olarak elde edildi. MRE ± SD değeri 0.94 ± 0.81 olarak bulundu.

Z point frontozygomatic suture, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 90.9, 95.8, 98.3 ve 99.1 olarak elde edildi. MRE ± SD değeri 1.08 ± 0.72 olarak bulundu.

Lower central incisor tip, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 90.9, 94.2, 97.5 ve 99.1 olarak elde edildi. MRE ± SD değeri 1.02 ± 0.77 olarak bulundu.

Lower cuspid tip, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 90.9, 94.2, 97.5 ve 98.3 olarak elde edildi. MRE ± SD değeri 1.10 ± 0.77 olarak bulundu.

Lower central incisor mesial, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 90.0, 95.0, 97.5 ve 99.1 olarak elde edildi. MRE ± SD değeri 1.00 ± 0.76 olarak bulundu.

Upper molar buccal root, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 89.2, 95.8, 100 ve 100 olarak elde edildi. MRE ± SD değeri 1.15 ± 0.62 olarak bulundu.

Lower central incisor mesial, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 89.2, 95.0, 97.5 ve 99.1 olarak elde edildi. MRE ± SD değeri 1.00 ± 0.75 olarak bulundu.

Lower molar buccal root, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 88.4, 95.0, 98.3 ve 98.3 olarak elde edildi. MRE ± SD değeri 1.27 ± 0.73 olarak bulundu.

Lower molar buccal root, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 87.6, 92.5, 97.5 ve 99.1 olarak elde edildi. MRE ± SD değeri 1.22 ± 0.71 olarak bulundu.

Z point frontozygomatic suture, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 85.1, 90.0, 93.3 ve 100 olarak elde edildi. MRE ± SD değeri 1.22 ± 0.86 olarak bulundu.

Lateral wall of nasal cavity, R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 81.8, 87.6, 93.3 ve 98.3 olarak elde edildi. MRE ± SD değeri 1.41 ± 1.20 olarak bulundu.

Jugal process, L (J) noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 80.9, 86.7, 90.9 ve 98.3 olarak elde edildi. MRE ± SD değeri 1.45 ± 0.95 olarak bulundu.

Lateral wall of nasal cavity, L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 77.6, 89.2, 94.2 ve 97.5 olarak elde edildi. MRE ± SD değeri 1.45 ± 1.16 olarak bulundu.

Jugal process, R (J) noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 76.8, 89.2, 96.6 ve 97.5 olarak elde edildi. MRE ± SD değeri 1.50 ± 0.98 olarak bulundu.

Nasal Septum noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 76.0, 85.1, 91.7 ve 96.6 olarak elde edildi. MRE ± SD değeri 1.52 ± 1.12 olarak bulundu.

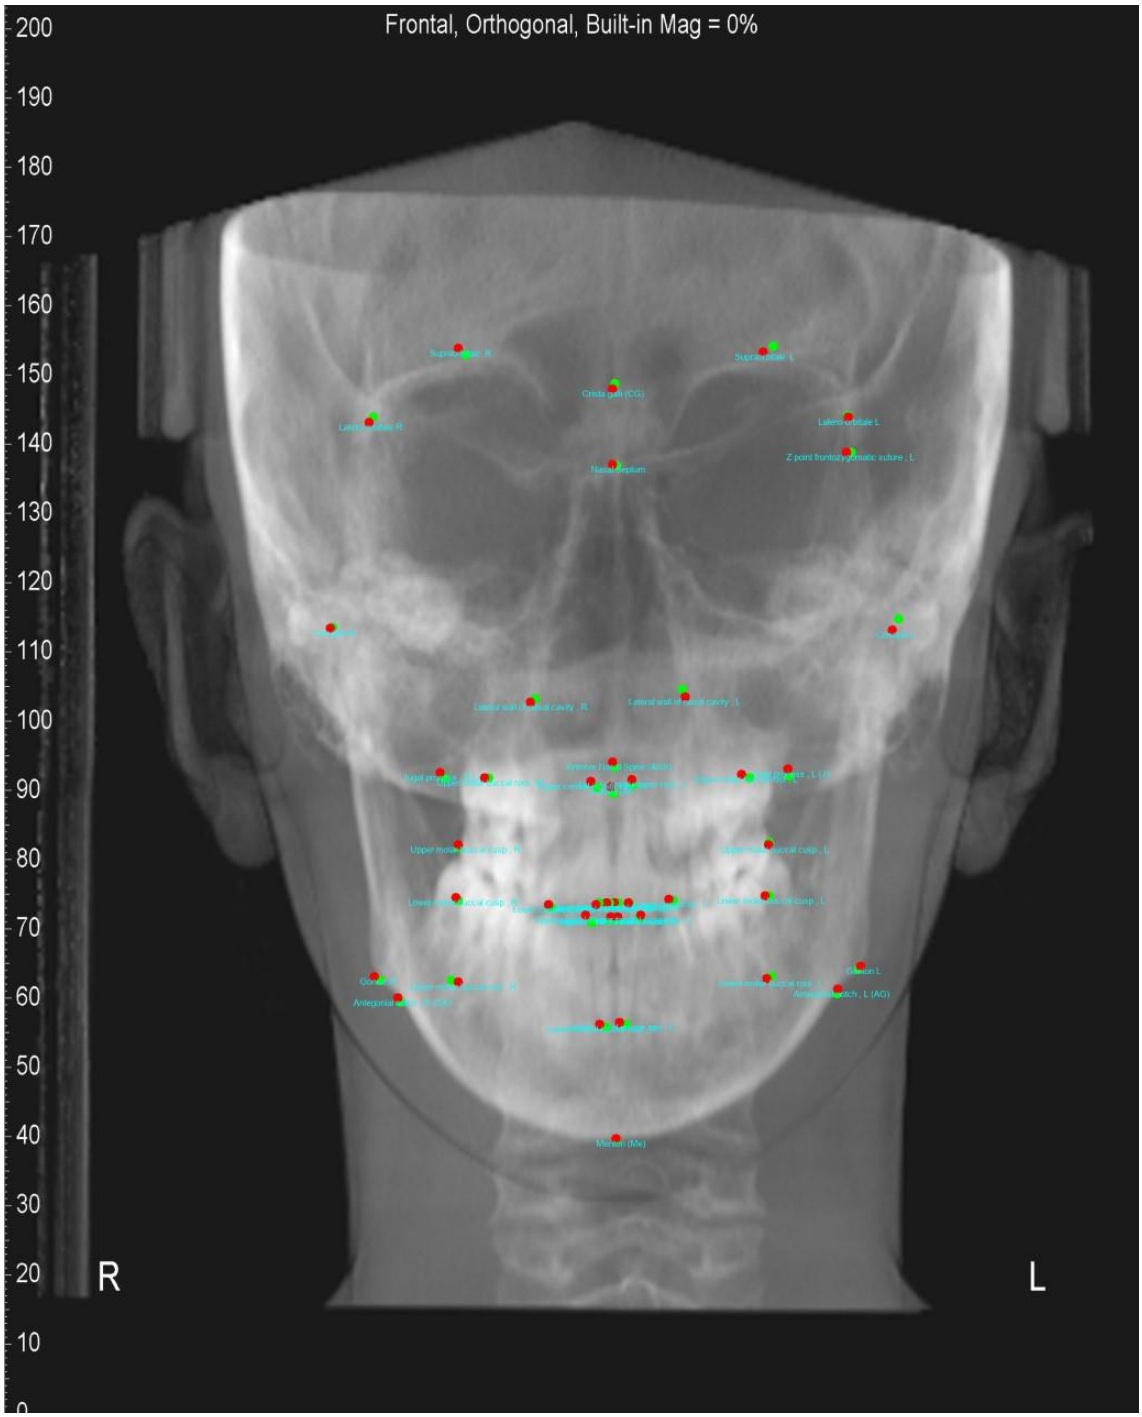
Condyle R noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 73.5, 85.9, 93.3 ve 98.3 olarak elde edildi. MRE ± SD değeri 1.56 ± 0.99 olarak bulundu.

Condyle L noktası için SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm için sırasıyla 72.7, 84.2, 90.0 ve 95.8 olarak elde edildi. MRE ± SD değeri 1.70 ± 1.08 olarak bulundu.

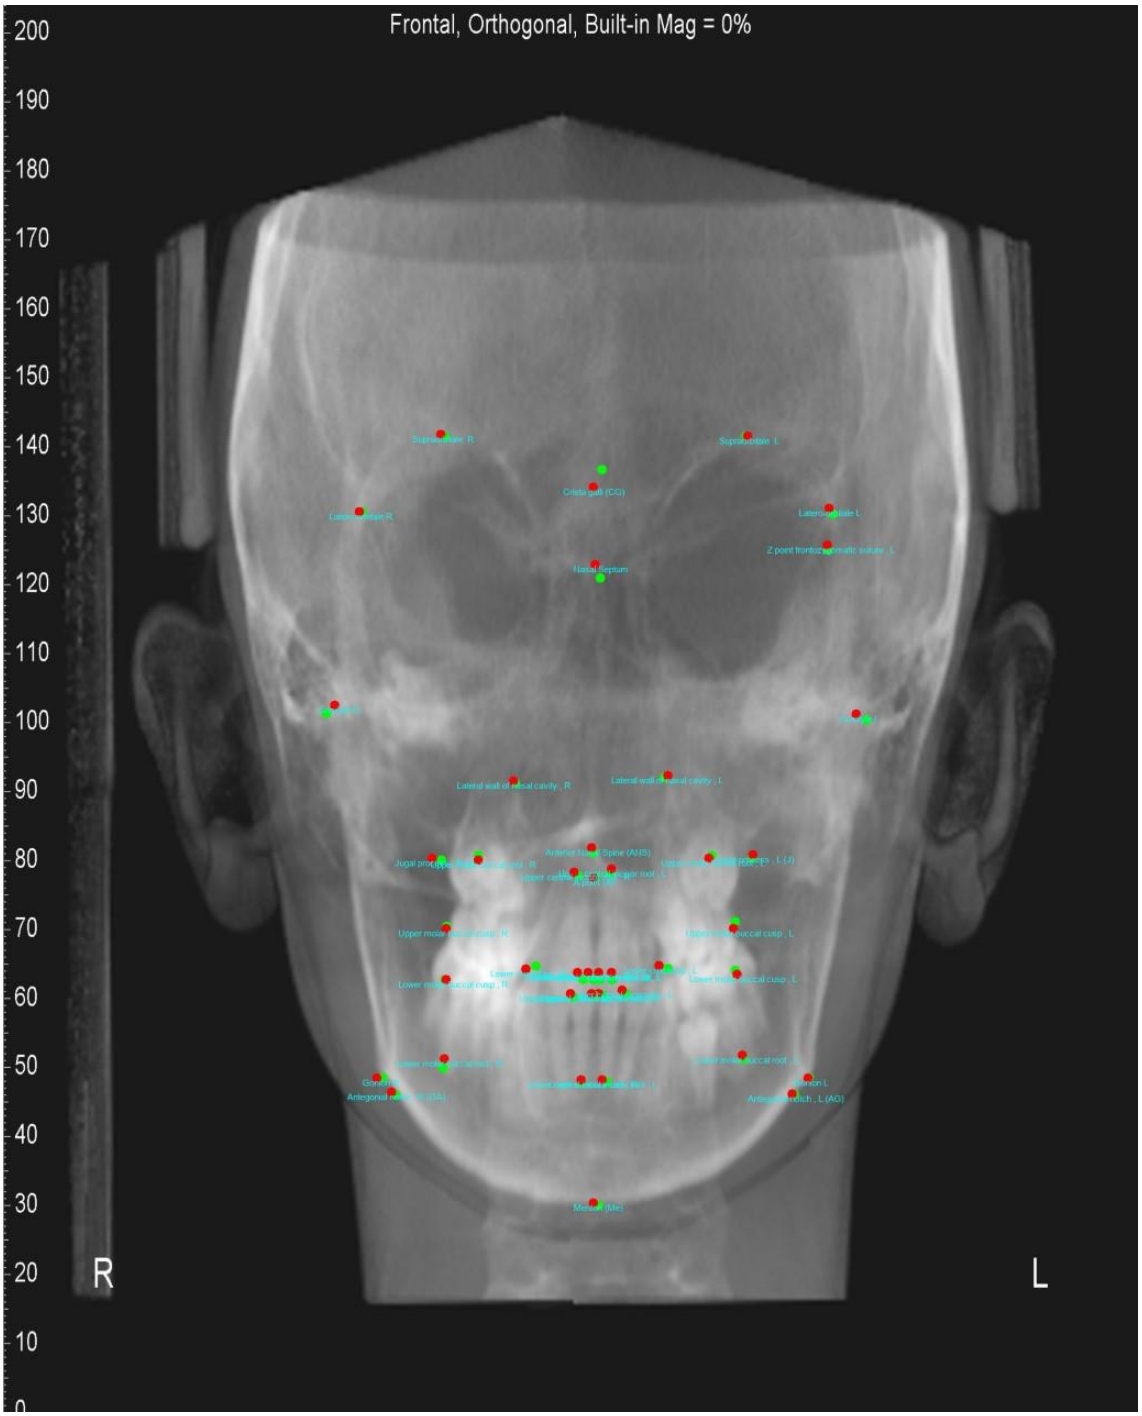
Test verilerinden elde edilen her bir anatomik dönüm noktasının MRE ve SDR değeri Tablo 4.1.'de özetlenmiştir.

Tablo 4.1. Sefalometrik nokta tespitinin SDR ve MRE değerleri

Point name	<=2.0	<=2.5	<=3.0	<=4.0	MRE	sd
A point (A)	0,9834710744	1	1	1	0,7973218057	0,4681580097
Antegonial notch, L (AG)	1	1	1	1	0,6097047898	0,2807083802
Antegonial notch, R (GA)	1	1	1	1	0,6377057195	0,4035520298
Anterior Nasal Spine (ANS)	0,9421487603	0,9917355372	1	1	0,9044163901	0,5480487614
Condyle L	0,7272727273	0,8429752066	0,9008264463	0,958677686	1,701758709	1,08675094
Condyle R	0,7355371901	0,8595041322	0,9338842975	0,9834710744	1,561850852	0,990909187
Crista galli (CG)	0,652892562	0,7190082645	0,7851239669	0,8512396694	2,05556151	1,624749001
Gonion L	1	1	1	1	0,6666830976	0,3093503959
Gonion R	0,9917355372	0,9917355372	1	1	0,6378113556	0,4117168509
Jugal process, L (J)	0,8099173554	0,867768595	0,9090909091	0,9834710744	1,450561268	0,9526332125
Jugal process, R (J)	0,7685950413	0,8925619835	0,9669421488	0,9752066116	1,508954682	0,984980176
Lateral wall of nasal cavity, L	0,7768595041	0,8925619835	0,9421487603	0,9752066116	1,451609437	1,163937514
Lateral wall of nasal cavity, R	0,8181818182	0,8760330579	0,9338842975	0,9834710744	1,4130027	1,20743653
Latero-orbitale L	0,958677686	0,9834710744	0,9917355372	1	0,901718475	0,5393860033
Latero-orbitale R	0,9256198347	0,9669421488	1	1	0,8915805902	0,6146907363
Lower central incisor mesial, L	0,8925619835	0,9504132231	0,9752066116	0,9917355372	1,005435041	0,7519354615
Lower central incisor mesial, R	0,9008264463	0,9504132231	0,9752066116	0,9917355372	1,008414028	0,7669345553
Lower central incisor root, L	0,9256198347	0,9834710744	0,9917355372	0,9917355372	1,02919158	0,6431358517
Lower central incisor root, R	0,9669421488	0,9917355372	1	1	0,9986101681	0,5482862709
Lower central incisor tip, L	0,9173553719	0,9421487603	0,9752066116	0,9917355372	1,033771411	0,752259778
Lower central incisor tip, R	0,9090909091	0,9421487603	0,9752066116	0,9917355372	1,02482421	0,7767519769
Lower cuspid tip, L	0,9338842975	0,9504132231	0,9752066116	0,9917355372	1,039100753	0,6883971192
Lower cuspid tip, R	0,9090909091	0,9421487603	0,9752066116	0,9834710744	1,107302757	0,7794297231
Lower molar buccal cusp, L	0,9421487603	0,9752066116	0,9834710744	0,9917355372	0,9184721291	0,629753088
Lower molar buccal cusp, R	0,9338842975	0,9669421488	1	1	0,9592712139	0,5935494043
Lower molar buccal root, L	0,8842975207	0,9504132231	0,9834710744	0,9834710744	1,278089363	0,7371729573
Lower molar buccal root, R	0,8760330579	0,9256198347	0,9752066116	0,9917355372	1,222851068	0,7188497502
Menton (Me)	0,9917355372	1	1	1	0,6939654761	0,4040491661
Nasal Septum	0,7603305785	0,8512396694	0,9173553719	0,9669421488	1,520318874	1,127783109
Supraorbitale L	0,958677686	1	1	1	0,9564365939	0,4872156259
Supraorbitale R	0,9173553719	0,9834710744	0,9917355372	1	1,010173501	0,631289721
Upper central incisor mesial, L	0,958677686	0,9834710744	0,9834710744	0,9834710744	0,9276265384	1,559126005
Upper central incisor mesial, R	0,9669421488	0,9834710744	0,9917355372	0,9917355372	0,7809313778	0,5602392684
Upper central incisor root, L	0,9669421488	0,9834710744	0,9834710744	0,9834710744	1,003350053	0,8544972753
Upper central incisor root, R	0,9834710744	1	1	1	0,8902367704	0,4838800285
Upper central incisor tip, L	0,9669421488	0,9834710744	0,9834710744	0,9834710744	0,9491818007	1,427277865
Upper central incisor tip, R	0,9752066116	0,9834710744	1	1	0,7944606014	0,503987098
Upper molar buccal cusp, L	0,9669421488	0,9917355372	0,9917355372	1	0,8315124052	0,5551298192
Upper molar buccal cusp, R	0,9338842975	0,9752066116	1	1	0,9477636343	0,5982828788
Upper molar buccal root, L	0,9421487603	0,9752066116	1	1	1,119294509	0,5773498603
Upper molar buccal root, R	0,8925619835	0,958677686	1	1	1,151683165	0,6251100992
Z point, L	0,9090909091	0,958677686	0,9834710744	0,9917355372	1,083745533	0,7201909316
Z point, R	0,8512396694	0,9008264463	0,9338842975	1	1,221392723	0,8602192811
Zygomatic arch, L (ZA)	0,9256198347	0,9752066116	0,9834710744	0,9917355372	0,9360869599	0,65314377
Zygomatic arch, R (ZA)	0,9173553719	0,9504132231	0,9669421488	0,9834710744	0,9483054628	0,8186550639



Şekil 4.1. Test sonucu görüntülerinin değerlendirilmesi-1 (Kırmızı noktalar uzman ortodontistin işaretlediği, yeşil noktalar yapay zeka uygulamasının işaretlediği noktalar)



Şekil 4.2. Test sonucu görüntülerinin değerlendirilmesi-2 (Kırmızı noktalar uzman ortodontistin işaretlediği, yeşil noktalar yapay zeka uygulamasının işaretlediği noktalar)

5. TARTIŞMA

Ortodontik tanı konulması amacıyla dişlerin birbirleriyle ve çenelerle ilişkisini saptamak, aynı zamanda çenelerin birbirleriyle ve kafa kaidesiyle olan ilişkisini incelemek için sefalometrik radyograflardan faydalanılmaktadır. Sefalometrik değerlendirme, hastada büyüme-gelişim döneminde meydana gelen, aktif ortodontik tedavi esnasında ve ortodontik tedavi bitim sonrası pekiştirme döneminde oluşabilecek değişikliklerin belirlenmesi amacıyla rutinde sıklıkla uygulanılmaktadır.[138]

Posteroanterior sefalometrik radyografiler; yatay düzlemde maksilla ve mandibulanın genişliğinin değerlendirilmesinde, bilateral iskeletsel ve dişsel yapıların dikey yön ilişkilerinin belirlenmesinde, diş arklarının kemik kaidesiyle olan genişlik ve açısal ilişkisinin değerlendirilmesinde, nazal kavite genişliğinin ölçülmesinde, maksilla-mandibuladaki iskeletsel ve dişsel asimetrilerin tespit edilmesinde ve de vertikal ve transvers fasiyal asimetrilerin belirlenmesinde yardımcı olmaktadırlar.[4, 5]

Sefalometrik görüntüler üzerinde yapılan analizler, ortodontik muayene sırasında doğru tanı konması açısından oldukça önemlidir. Klinisyenler sefalometrik analiz olmaksızın yapılan değerlendirmelerde bazen hataya düşebilmektedirler.[139, 140] Çeşitli sefalometrik analiz yöntemleri mevcuttur, bunlardan biri olan ve uzun yıllardır kullanılan geleneksel analiz yönteminde, sefalometrik film üzerine yerleştirilen özel bir çizim kağıdına, çizim kalemi ile istenen anatomik noktalar işaretlenmektedir. Bu yöntemin zaman alıcı olması ve hataya müsait olması sebebiyle, bilgisayar teknolojisindeki son dönemde meydana gelen değişiklikler ile dijital ortamda sefalometrik analiz yöntemine rağbet artmıştır.[141] Analiz bilgisayar tarafından yapıldığı için ölçüm esnasında oluşabilecek hataların önüne geçildiği savunulmaktadır ancak referans noktalar klinisyen

tarafından belirlendiği için konvansiyonel sefalometrik analiz metoduna benzer hataların burada da oluşabileceği belirtilmiştir.[11, 13] Analizin sağlanması için gereken sürenin azaltılması ve referans noktaların öznellikten uzaklaşılıp daha sağlıklı belirlenmesinin sağlanması gayesiyle otomatik sefalometrik analiz girişimleri olmuştur.[48] Bu analizde yazılım tarafından, referans noktaları otomatik olarak belirlenir ve gerekli ölçümler yapılır. Otomatik analizdeki en önemli faktör anatomik noktaların belirlenmesidir çünkü ölçüm işlemleri, bilgisayar destekli sefalometrik analiz yöntemlerinde de hemen hemen hatasız yapılmaktadır.[14]

Uygulanan yöntemden bağımsız olarak asıl önemli nokta, yapılan sefalometrik inceleme ölçümlerinin güvenilir olmasıdır. Literatüre bakıldığında el ile çizim tekniği ve yarı otomatik dijital sefalometrik analizlerle alakalı birçok çalışma bulunmasına rağmen tam otomatik dijital sefalometrik analizlerin güvenilir olup olmadığını değerlendiren yeterli sayıda araştırma bulunmamaktadır. [44, 142]

Sefalometrik görüntülerin analizi çok önemli olmasına rağmen, zaman alıcı ve güçlü bir işlemdir ve analizin sonucu kişiden kişiye değişebilir. Dikkate alındığında, AI algoritmalarını kullanan otomatik sefalometrik analiz görüşü faydalı bulunmuş ve literatürde farklı yöntemlerin kullanıldığı pek çok çalışma mevcuttur. Bu görüşe göre, Uluslararası Biyomedikal Görüntüleme Sempozyumu (ISBI) ve Elektrik ve Elektronik Mühendisleri Enstitüsü tarafından otomatik sefalometrik dönüm noktası saptama zorlukları düzenlendi ve 19 sefalometrik simgeden oluşan halka açık veri seti oluşturuldu. Bu veri seti kullanılarak, sefalometrik dönüm noktası tespiti için Bayes evrişimli sinir ağları ve kademeli CNN'ler gibi farklı AI yöntemleri uygulandı.[143]

Moon ve ark.[144] bir derin öğrenme sistemini yapay zeka olarak pratik kullanım amacıyla yeterince eğitmek için ne kadar öğrenme verisinin gerekli olabileceğini

araştırmışlardır. AI'nın tespit hatalarının sadece öğrenme verilerinin miktarı ile değil, aynı zamanda görüntü başına tespit edilen hedeflerin sayısı ile de önemli ölçüde ilişkili olduğunu gösterdiler. Yapay zekanın eğitim prosedürü sırasında ne kadar çok veri uygulanırsa, gözlemlenen algılama hataları o kadar küçük olur. Klinik olarak kabul edilebilir MRE için karar kriterleri, insan klinisyenler arasındaki inceleyiciler arası farktı. Tahmin prosedürü boyunca, yapay zekayı insan denetçileri kadar doğru geliştirmek için en az 2300 öğrenme verisi gerekli görünüyordu. Bizim çalışmamızda Eskişehir Osmangazi Üniversitesi'ne başvuran 1295 hastadan alınan radyografiler veri setimizi oluşturmuş ve sefalometrik nokta tespiti için Far-net derin öğrenme mimarisi kullanılmıştır.

Ülkür ve ark.[145] sefalometrik görüntülerde iki klinisyen tarafından anatomik landmark tespiti yapmışlardır. İşaretleme manuel olarak yapılmış ve 1 ay sonra aynı işlem tekrarlanmıştır. Elde edilen bulgulara göre aynı klinisyen tarafından yapılan değerlendirmelerin sonuçlarının daha tutarlı olduğu görülmüştür. Yine Major ve ark.[146] tarafından yapılan bir çalışmada, tek bir klinisyen ve birden fazla klinisyen arası uygulamaların güvenilirlik açısından farklarını ölçmek için posteroanterior sefalometrik görüntüler üzerinde 52 anatomik nokta işaretlenmiştir. Birçok sefalometrik nokta için klinisyenler arası tanımlama hatası, aynı klinisyen tarafından yapılanlara oranla daha büyük bulunmuştur. Bizim de çalışmamızda referans noktalarını etiketleme işlemini, klinisyenler arası oluşan değerlendirme farkını engellemek için tek bir klinisyen yapmıştır.

Shokri ve ark.[147] CBCT ve geleneksel posteroanterior sefalogramlarda kafa pozisyonunun değiştirilmesinin maksillofasiyal bölgedeki transversal ölçümler üzerindeki etkilerini araştırmışlardır. Baş konumunun değiştirilmesi sonucu CBCT ile yapılan ölçümler konvansiyonel posteroanterior sefalogramlarda yapılan ölçümlere göre

daha fazla etkilenmiştir, dolayısıyla tedavi planı da etkilenebilir. Çalışmamızda 1295 hastanın KIBT görüntülerinden kaydedilmiş DICOM dosyalarından Dolphin Imaging 11.95 software (Dolphin Imaging and Management Solutions, Chatsworth, Calif) yazılımı kullanılarak baş pozisyonu Frankfort Horizontal düzlemi yere paralel olacak şekilde ayarlanıp daha sonrasında sefalometrik radyograflar oluşturuldu, böylece kafa pozisyonu değişiklikleri sonucu ortaya çıkabilecek tutarsızlıkların en aza indirgenmesi amaçlandı.

2 boyutlu ve 3 boyutlu sefalometrik görüntülerde anatomik landmark tespiti için DL' yi içeren çalışmaların sayısı hızla artarken, ortaya çıkan sonuçların ne kadar sağlam ve tutarlı olduğu belirsizliğini koruyor. Ayrıca, DL' nin doğruluğunun veya çalışmaların kalitesinin zamanla gelişip gelişmediği veya 2 boyutlu ve 3 boyutlu görüntülerde doğrulukta farklılıklar olup olmadığı belirsizdir. Kim ve ark.[148] posteroanterior görüntülerde sefalometrik nokta tespitinde, CBCT ile sentezlenmiş posteroanterior sefalogramları konvansiyonel posteroanterior sefalogramlara göre daha güvenilir bulmuşlardır. Biz de çalışmamızda daha başarılı sonuçlar elde edebilmek amacıyla, 3 boyutlu görüntülerden oluşturduğumuz 2 boyutlu sefalogramlar üzerinde nokta tespitinde DL' nin doğruluğunu araştırarak belirsizliğin giderilmesine yardımcı olmak istemekteyiz.

Uğurlu ve ark.[136] 1360 lateral sefalometrik radyograf üzerinde FAR-net derin öğrenme modelini, Lee ve ark.[149] 400 lateral sefalometrik radyograf üzerinde Bayesian derin öğrenme modelini, Kim ve ark.[150] 3150 lateral sefalometrik radyograf üzerinde iki kademeli derin öğrenme modelini, Hwang ve ark.[151] 1311 lateral sefalometrik radyograf üzerinde YOLOv3 derin öğrenme modelini kullanmışlardır. Park ve ark.[152] 1311 adet lateral sefalometrik radyograf üzerinde otomatik sefalometrik nokta tespiti için Single Shot Multibox Detector (SSD) ve You-Only-Look-Once version 3 (YOLOv3) adlı 2 derin öğrenme mekanizmasını karşılaştırmışlardır, çıkan sonuçlara göre YOLOv3'ün doğruluk

ve hesaplama süresi bakımından SSD' den daha iyi performans gösterdiğini bildirmişlerdir. Kim ve ark.[148] 430 posteroanterior sefalometrik radyograf üzerinde çok aşamalı CNN modelini (kişisel bir bilgisayarda Keras programı uygulanarak) kullanmışlardır ve en düşük doğruluk gösteren sol Kondil noktası olmuştur. Gil ve ark.[153] 2798 posteroanteior sefalometrik radyograf üzerinde iki kademeli derin öğrenme modelini kullanmışlardır ve en yüksek SDR oranına sahip noktalar sağ ve sol Antegonion noktaları olmuştur. Biz de çalışmamızda 1295 posteroanterior sefalometrik radyograf üzerinde sefalometrik nokta tespiti için FARNet derin öğrenme mimarisi modelini kullandık.

Gil ve ark.[153] evrişimli sinir ağı katmanlarını kullanarak posteroanterior sefalometrik noktaların otomatik olarak tanımlanmasının doğruluğunu değerlendirmişlerdir. Toplamda 2798 posteroanterior sefalogramdan, 2075 tanesi eğitim seti ve 343 tanesi doğrulama seti olmak üzere 2418 görüntü 16 adet posteroanterior sefalometrik noktanın otomatik olarak tanımlanması için oluşturulan CNN algoritmasını eğitmek amacıyla kullanılmıştır. Kalan 380 test seti görüntüleri, CNN algoritması kullanılarak otomatik tanımlamanın doğruluğunu değerlendirmek için klinisyen tarafından yapılan tanımlamayla karşılaştırmışlardır. En düşük hata oranı sağ ve sol antegonion noktalarında, en yüksek hata oranı da üst sağ birinci molar kök ucunda gözlenmiştir. Evrişimli sinir ağı katmanları, posteroanterior sefalometrik noktaların otomatik olarak tanımlanması için manuel tanımlamaya etkili bir alternatif olarak gösterilmiştir. Bizim çalışmamızda da en düşük hata oranı sağ ve sol Antegonion noktalarında bulunmuştur, en yüksek hata oranı ise Crista Galli noktasında bulunmuştur.

Günümüze kadar çeşitli yapay zeka algoritmaları kullanılarak lateral sefalometrilerde otomatik analizin yapıldığı çok sayıda araştırma bulunmaktadır ancak posteroanterior filmler için aynısını söyleyememekteyiz. Kim ve ark.[148] da yaptıkları

çalışmada bu konuya değinmişler ve kademeli evişimli sinir ağlarını uygulayarak otomatik landmark tespiti için KIBT görüntülerinden elde edilen posteroanterior sefalogramları kullanmışlardır. 430 adet posteroanterior görüntü içinden 345 tanesi çok aşamalı evrişimli sinir ağlarının eğitimi için ve kalan 85 tanesi de test veri seti olarak kullanılmıştır. Yapay zeka algoritmalarıyla yapılan analizde en düşük doğruluk sol Kondil noktasında tespit edilmiştir. Klinik olarak yeterince olumlu sonuca ulaşılamamasına rağmen yapay zeka ile sefalometrik nokta tespitinin manuel tanımlamadan daha iyi tutarlılık gösterdiği yönünde görüşler ortaya konmuştur.

Takeda ve ark.[154] mandibular deviasyon tespiti için posteroanterior sefalometrik filmlerde bazı anatomik landmark işaretlemesi yaparak derin öğrenme merkezli CNN algoritması kullanmışlardır. Yüz asimetrisinin tespiti için önerilen CNN algoritmasının değerlendirme için harcanan süreyi kısaltabileceği, ortodontik teşhisin daha rahat konulmasını sağlayabileceği bildirilmiştir.

Bu çalışmamızda ortodontik tanıyı ve tedavi planını belirleyebilmek amacıyla yapılan ölçümler için kullandığımız sefalometrik noktalarını, bir yapay zeka algoritması ile otomatik olarak işaretleyebilen program kullandık. 3 boyutlu görüntülerden elde ettiğimiz 2 boyutlu radyograflar üzerinde 23 adet iskeletsel noktayı ve 22 adet dişşel noktayı CranioCatch programında etiketledik. Yapılan analizlerin sonucunda toplamda 14 adet iskeletsel noktanın 2 mm' lik aralıkta SDR değeri %90' ın üzerinde bulunmuştur. 22 adet dişsel noktadan 18 tanesinde 2 mm'lik aralıkta SDR değeri %90' ın üzerinde bulunmuştur. Dişsel noktalarda iskeletsel noktalara göre daha başarılı sonuçlar elde edilmiştir, bunun sebebi olarak dişsel yapılar, çevre yapılardan daha iyi ayırt edilebildikleri için bu alanda daha doğru konumda işaretleme yapılabilmesi olduğu düşünülmektedir. En yüksek SDR oranı sağ ve sol Antegonion ve sol Gonion noktasında, en düşük SDR oranı ise Crista Galli noktasında elde edilmiştir. Crista Galli noktasındaki

başarısızlığın sebebi olarak, alınan KIBT'lerin ultra düşük doz olmasından kaynaklı görüntü netliğinin azalması nedeniyle etiketleme sırasında zorlanılması olabileceği düşünülmektedir. Crista Galli'den sonra en düşük SDR değeri sağ ve sol Condyle noktalarında bulunmuştur, yine alınan KIBT'lerin ultra düşük doz olması ve çevre anatomik yapıların görüntülerinin üst üste binmesinden dolayı kondil sınırlarının bazı filmlerde tam olarak belirlenememesi sebebiyle böyle bir sonucun doğduğu düşünülmektedir.

Görüntü kalitesi kötü olan radyografik görüntüleri bulunan (metal artefaktı, çekim sırasında oluşan pozisyon hataları kaynaklı artefaktlar vb. sebeplerle meydana gelen bozukluklar), kraniofasiyal sendromu, dudak damak yarığı olan, herhangi bir travmaya bağlı yüz deformitesine sahip hastaların radyografik görüntüleri çalışmaya dahil edilmemiştir. Ayrıca protetik restorasyon ve dental implanta sahip hastaların ve ortognatik cerrahi görmüş hastaların görüntüleri de çalışma dışı tutulmuştur. Çalışmamızın dar bir popülasyonda yapılmış olması limitasyonumuzdur.

Çalışmamızda veri setini oluşturan bütün görüntüler aynı KIBT cihazında, aynı parametrelerle çekilen görüntülerden oluşmaktadır. Görüntülerin oryantasyonları da Dolphin programında aynı şekilde yapılmıştır. Farklı cihazlar, farklı voksel boyutlarına sahip görüntüler ve farklı çekim parametreleri uygulanarak elde edilecek görüntülerle yapılacak olan çalışmalar ile daha etkin AI modelleri elde edilebilir. Ayrıca elde edilen AI modellerinin başarısının daha iyi değerlendirilebilmesi için eksternal test veri seti kullanılması önerilmektedir.

6. SONUÇ ve ÖNERİLER

Konik ışınlı bilgisayarlı tomografi görüntülerinden elde edilen posteroanterior sefalometrik görüntüler üzerinde derin öğrenme yöntemiyle geliştirilmiş yapay zeka algoritmalarının kullanılarak sefalometrik noktaların tespitinin incelendiği bu çalışmada şu sonuçlar elde edilmiştir:

Geliştirdiğimiz AI algoritmalarının, KIBT görüntülerinden elde ettiğimiz 2 boyutlu sefalometrik radyograflar üzerindeki etiketlenen iskeletsel ve dişsel noktaların tespit sonuçları umut vericidir. Çalışmada eğitilen AI modelinde SDR oranı 2 mm' lik aralıkta, işaretlenen toplam 45 noktada 6 nokta haricinde %80 üzerinde değerler göstermiştir.

Elde edilen sonuçlar AI destekli sistemlerin, klinik rutininde hekimlere zaman kazandıracak bir karar destek mekanizması işlevi görme potansiyeline sahip olabileceğini göstermektedir.

Veri setine dâhil etmediğimiz hasta grupları çalışmamızın limitasyonlarından biridir. İlerleyen dönemlerde yapılacak olan çalışmalarda çalışmaya dâhil etme kriterleri genişletilerek daha geniş bir popülasyon üzerinde çalışılarak, klinik uygulama açısından daha yararlı AI algoritmaları elde edilmesi sağlanabilir.

Gelecek çalışmalarda farklı cihazlardan elde edilen, farklı çözünürlüklere sahip ve farklı çekim parametreleri ile elde edilmiş görüntülerin kullanılması klinik kullanım açısından daha geçerli AI modellerinin elde edilmesini sağlayacaktır. AI modellerinin

başarısının daha iyi tespit edilebilmesi için veri sayısının daha fazla olduğu çalışmalar yapılmalıdır.

Ortodontik tanı ve tedavi planlaması, hastanın genel diş durumu, yüz görünümü ve iskelet oryantasyonu gibi çeşitli faktörleri dikkate alır. Derin bir öğrenme modeli, teknoloji ve eğitim veri kalitesindeki sınırlamaları nedeniyle uzmanların ince karar verme yeteneğinden yoksun olabilir ve bu nedenle onu insan teşhisinden daha az kullanışlı hale getirir. Bununla birlikte, veri kalitesi ve miktarındaki iyileştirmelerle bir tanı sisteminin sürekli iyileştirilmesiyle, AI'nın yakın gelecekte ortodonti klinik uygulamalarına verimli yardım sağlayacağına inanıyoruz.

KAYNAKLAR

1. Durão AR, Alqerban A, Ferreira AP, Jacobs R. Influence of lateral cephalometric radiography in orthodontic diagnosis and treatment planning. Angle Orthod. 2015;85(2):206-10.

2. İşcan H. Ortodontik muayene ve ortodontik tedaviler. Ankara: GÜ Diş Hek. Vakfı GÜİV yayınları 1991;9-167.

3. Graber TM. Orthodontics: Current principles and techniques. St Louis: Elsevier 2000; 330-332.

4. Ricketts RM. Perspectives in the clinical application of cephalometrics: the first fifty years. Angle Orthod. 1981;51(2):115-50.

5. Bergman R. Practical applications of the PA cephalometric headfilm. Orthodontic review 1988;2(2):20-26.

6. Athanasiou AE. Orthodontic cephalometry. London: Mosby-Wolfe Publishing Co. 1st edition. 1995; 42-44.

7. Ricketts RM, Grummons D. Frontal Cephalometrics: Practical Applications, Part I. World J Orthod. 2003;4:297-316.

8. Grummons D. Nonextraction Emphasis: Space Gaining Efficiencies, Part I. World J Orthod. 2001;2:21-32.

9. Grummons D. Maxillary asymmetry and frontal analysis. Clinical impressions 1999;8(3):2-9.

10. Ricketts RM. The golden divider. J Clin Orthod. 1981;15(11):752-59.

11. Liu J-K, Chen Y-T, Cheng K-S. Accuracy of computerized automatic identification of cephalometric landmarks. Am J Orthod Dentofacial Orthop. 2000;118(5):535-40.

12. Chen Y-J, Chen S-K, Chung-Chen Yao J, Chang H-F. The effects of differences in landmark identification on the cephalometric measurements in traditional versus digitized cephalometry. Angle Orthod. 2004;74(2):155-61.

13. Gravely J, Benzies PM. The clinical significance of tracing error in cephalometry. Br J Orthod. 1974;1(3):95-101.

14. Leonardi R, Giordano D, Maiorana F, Spampinato C. Automatic cephalometric analysis: a systematic review. Angle Orthod. 2008;78(1):145-51.

15. Chartrand G, Cheng PM, Vorontsov E, Drozdzal M, Turcotte S, Pal CJ, Kadoury S, Tang A. Deep learning: a primer for radiologists. Radiographics 2017;37(7):2113-31.

16. Khanna S. Artificial intelligence: contemporary applications and future compass. Int Dent J. 2010;60(4):269-72.

17. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, Sarode SC, Bhandi S. Developments, application, and performance of artificial intelligence in dentistry–A systematic review. J Dent Sci. 2021;16(1):508-22.

18. Xie X, Wang L, Wang A. Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. Angle Orthod. 2010;80(2):262-66.

19. Kök H, Acilar AM, İzgi MS. Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. Prog Orthod. 2019;20(1):1-10.

20. Bulatova G, Kusnoto B, Grace V, Tsay TP, Avenetti DM, Sanchez FJC. Assessment of automatic cephalometric landmark identification using artificial intelligence. Orthod Craniofac Res. 2021 Dec;24 Suppl 2:37-42.

21. Allen WI. Historical aspects of roentgenographic cephalometry. Am J Orthod. 1963;49(6):451-59.

22. Pacini A. Roentgen ray anthropometry of the skull. J Radiol. 1922;3(8):322-31.

23. Broadbent BH. A new x-ray technique and its application to orthodontia. Angle Orthod. 1931;1(2):45-66.

24. Miyashita K, Dixon A.D. Contemporary cephalometric radiography. Quintessence Publishing Co, Inc.;Batavia, IL, USA 1996.

25. Ricketts RM. Cephalometric analysis and synthesis. Angle Orthod. 1961;31(3):141-56.

26. Hatton M, Grainger R. Reliability of measurements from cephalograms at the Burlington Orthodontic Research Centre. J Dent Res. 1958;37(5):853-59.

27. BERGERSEN EO. Enlargement and distortion in cephalometric radiography: compensation tables for linear measurements. Angle Orthod. 1980;50(3):230-44.

28. Houston W. The analysis of errors in orthodontic measurements. Am J Orthod. 1983;83(5):382-90.

29. Baumrind S, Frantz RC. The reliability of head film measurements: 1. Landmark identification. Am J Orthod. 1971;60(2):111-27.

30. Mostafa Y, El-Mangoury N, Salah A, Rasmy E. Automated cephalographic soft-tissue analysis. J Clin Orthod. 1990;24(9):539-43.

31. Harorli A, Akgül M, Dağistan S. Diş hekimliği radyolojisi. Erzurum. Eser Offset Matbaası 2006;1287-99.

32. Versteeg C, Sanderink G, Van Der Stelt P. Efficacy of digital intra-oral radiography in clinical dentistry. J Dent. 1997;25(3-4):215-24.

33. Brennan J. An introduction to digital radiography in dentistry. J Orthod. 2002 Mar;29(1):66-9.

34. Forsyth D, Shaw W, Richmond S. Digital imaging of cephalometric radiography, part 1: advantages and limitations of digital imaging. Angle Orthod. 1996;66(1):37-42.

35. LeCun Y, Boser B, Denker J, Henderson D, Howard R, Hubbard W, Jackel L. Handwritten digit recognition with a back-propagation network, in: Advances in neural information processing systems 1990;396-404.

36. Gottlieb EL, Nelson AH, Vogels 3rd D. 1990 JCO study of orthodontic diagnosis and treatment procedures. 1. Results and trends. J Clin Orthod. 1991;25(3):145-56.

37. Tweed CH. The Frankfort-mandibular plane angle in orthodontic diagnosis, classification, treatment planning, and prognosis. Am J Orthod Oral Surg. 1946;32(4):175-230.

38. Athanasiou A. Orthodontic Cephalometry London: Mosby International. 1995.

39. İşman O. İki farklı sefalometrik çizim ve analiz tekniğinin sert ve yumuşak doku analiz sonuçlarının karşılaştırılması. Yeditepe Üniversitesi Doktora Tezi 2010;25

40. Çelik EE. Konvansiyonel teknik ve bilgisayar ile yapılmış sefalometrik analizlerin güvenilirlik açısından karşılaştırılması. Başkent Üniversitesi Doktora Tezi 2007;6.

41. Houston W, Maher R, McElroy D, Sherriff M. Sources of error in measurements from cephalometric radiographs. Eur J Orthod. 1986;8(3):149-51.

42. Celik E, Polat-Ozsoy O, Toygar Memikoglu TU. Comparison of cephalometric measurements with digital versus conventional cephalometric analysis. Eur J Orthod. 2009;31(3):241-46.

43. Carlos Quintero J, Trosien A, Hatcher D, Kapila S. Craniofacial imaging in orthodontics: historical perspective, current status, and future developments. Angle Orthod. 1999;69(6):491-506.

44. Sayinsu K, Isik F, Trakyali G, Arun T. An evaluation of the errors in cephalometric measurements on scanned cephalometric images and conventional tracings. Eur J Orthod. 2007;29(1):105-08.

45. Gregston MD, Kula T, Hardman P, Glaros A, Kula K In *A comparison of conventional and digital radiographic methods and cephalometric analysis software: I. hard tissue*, Seminars in Orthodontics, Elsevier: 2004; 204-11.

46. Uysal T, Baysal A, Yagci A. Evaluation of speed, repeatability, and reproducibility of digital radiography with manual versus computer-assisted cephalometric analyses. Eur J Orthod. 2009;31(5):523-28.

47. Baumrind S, Miller DM. Computer-aided head film analysis: the University of California San Francisco method. Am J Orthod. 1980;78(1):41-65.

48. Hutton TJ, Cunningham S, Hammond P. An evaluation of active shape models for the automatic identification of cephalometric landmarks. Eur J Orthod. 2000;22(5):499-508.

49. MIDTGÅRD J, BJÖRK G, Linder-Aronson S. Reproducibility of cephalometric landmarks and errors of measurements of cephalometric cranial distances. Angle Orthod. 1974;44(1):56-61.

50. Kazandjian S, Kiliaridis S, Mavropoulos A. Validity and reliability of a new edge-based computerized method for identification of cephalometric landmarks. Angle Orthod. 2006;76(4):619-24.

51. Van Vlijmen O, Maal T, Bergé S, Bronkhorst E, Katsaros C, Kuijpers-Jagtman A. A comparison between 2D and 3D cephalometry on CBCT scans of human skulls. Int J Oral Maxillofac Surg. 2010;39(2):156-60.

52. Scarfe WC, Li Z, Aboelmaaty W, Scott SA, Farman AG. Maxillofacial cone beam computed tomography: essence, elements and steps to interpretation. Aust Dent J. 2012 Mar;57 Suppl 1:46-60.

53. Baumrind S In *Integrated three-dimensional craniofacialmapping: Background, principles, and perspectives*, Seminars in Orthodontics, Elsevier: 2001; 223-32.

54. Hornak JP. The Basics of MRI. Rochester Institute of Technology. Center for Imaging Science 1996.

55. Sener S, Akgünlü F. Correlation of different MRI characteristics of anterior disc displacement with reduction and without reduction. J Contemp Dent Pract 2005;6(1):26-36.

56. Cevidanes LH, Franco AA, Gerig G, Proffit WR, Slice DE, Enlow DH, Lederman HM, Amorim L, Scanavini MA, Vigorito JW. Comparison of relative mandibular growth vectors with high-resolution 3-dimensional imaging. Am J Orthod Dentofacial Orthop. 2005;128(1):27-34.

57. Aldrich JE. Basic physics of ultrasound imaging. Crit Care Med. 2007;35(5):S131-S37.

58. Kiliaridis S, Kälebo P. Masseter muscle thickness measured by ultrasonography and its relation to facial morphology. J Dent Res. 1991;70(9):1262-65.

59. Şatıroğlu F, Arun T, Işık F. Comparative data on facial morphology and muscle thickness using ultrasonography. Eur J Orthod. 2005;27(6):562-67.

60. KAMBUROĞLU K, Buket A, YAKAR EN, PAKSOY CS. Dentomaksillofasiyal Konik Işın Demetli Bilgisayarlı Tomografi Bölüm 1: Temel Prensipler. ADO Klinik Bilimler Dergisi 2012;6(1):1125-36.

61. Dawood A, Patel S, Brown J. Cone beam CT in dental practice. Br Dent J. 2009;207(1):23-28.

62. Zinreich SJ, Kennedy DW, Rosenbaum AE, Gayler B, Kumar AJ, Stammberger H. Paranasal sinuses: CT imaging requirements for endoscopic surgery. Radiology. 1987;163(3):769-75.

63. White SC. Cone-beam imaging in dentistry. Health Phys. 2008;95(5):628-37.

64. Mozzo P, Procacci C, Tacconi A, Tinazzi Martini P, Bergamo Andreis I. A new volumetric CT machine for dental imaging based on the cone-beam technique: preliminary results. Eur Radiol. 1998;8(9):1558-64.

65. White SC, Pharoah MJ. Oral radiology-E-Book: Principles and interpretation. Baskı. Elsevier Health Sciences; 2014.

66. Barghan S, Tetradis S, Mallya S. Application of cone beam computed tomography for assessment of the temporomandibular joints. Aust Dent J. 2012;57109-18.

67. Farman AG, Scarfe WC In *The basics of maxillofacial cone beam computed tomography*, Seminars in Orthodontics, Elsevier: 2009; 2-13.

68. Kiarudi AH, Eghbal MJ, Safi Y, Aghdasi MM, Fazlyab M. The applications of cone-beam computed tomography in endodontics: a review of literature. Iran Endod J. 2015;10(1):16.

69. MacDonald-Jankowski DS, Orpe EC. Computed tomography for oral and maxillofacial surgeons. Part 2: cone-beam computed tomography. Asian J Oral Maxillofac Surg. 2006;18(2):85-92.

70. Scarfe WC, Farman AG, Sukovic P. Clinical applications of cone-beam computed tomography in dental practice. J Can Dent Assoc. 2006;72(1):75.

71. Hodez C, Griffaton-Taillandier C, Bensimon I. Cone-beam imaging: applications in ENT. Eur Ann Otorhinolaryngol Head Neck Dis. 2011;128(2):65-78.

72. Carter L, Farman AG, Geist J, Scarfe WC, Angelopoulos C, Nair MK, Hildebolt CF, Tyndall D, Shrout M. American Academy of Oral and Maxillofacial Radiology executive opinion statement on performing and interpreting diagnostic cone beam computed tomography. Oral Surg Oral Med Oral Pathol Oral Radiol Endod. 2008;106(4):561-62.

73. Iannucci J, Howerton LJ. Dental radiography-E-book: principles and techniques. Baskı. Elsevier Health Sciences; 2021.

74. Suomalainen A, Pakbaznejad Esmaeili E, Robinson S. Dentomaxillofacial imaging with panoramic views and cone beam CT. Insights Imaging. 2015;6(1):1-16.

75. Canger E M, Çelenk P. Dünyada ve Türkiye'de diş hekimliği radyolojisinin gelişimi. Türkiye klinikleri J Med Ethics. 2005; 13:48-54.

76. Caruso P, Silvestri E, Sconfienza LM. Cone beam CT and 3D imaging: A practical guide. Baskı. Springer; 2013.

77. Hilgers ML, Scarfe WC, Scheetz JP, Farman AG. Accuracy of linear temporomandibular joint measurements with cone beam computed tomography and digital cephalometric radiography. Am J Orthod Dentofacial Orthop. 2005;128(6):803-11.

78. Mah JK, Yi L, Huang RC, Choo H In *Advanced applications of cone beam computed tomography in orthodontics*, Seminars in Orthodontics, Elsevier: 2011; 57-71.

79. Lin Y, Fu Z, Ma L, Li W. Cone-beam computed tomography–synthesized cephalometric study of operated unilateral cleft lip and palate and noncleft children with Class III skeletal relationship. Am J Orthod Dentofacial Orthop. 2016;150(5):802-10.

80. Tulunoglu O, Esenlik E, Gulsen A, Tulunoglu I. A comparison of three-dimensional and two-dimensional cephalometric evaluations of children with cleft lip and palate. Eur J Dent. 2011;5(04):451-58.

81. Mattos CT, Cruz CV, da Matta TCS, de Abreu Pereira L, de Almeida Solon-de-Mello P, de Oliveira Ruellas AC, Sant'Anna EF. Reliability of upper airway linear, area, and volumetric measurements in cone-beam computed tomography. Am J Orthod Dentofacial Orthop. 2014;145(2):188-97.

82. Oh K-M, Hong J-S, Kim Y-J, Cevidanes LS, Park Y-H. Three-dimensional analysis of pharyngeal airway form in children with anteroposterior facial patterns. Angle Orthod. 2011;81(6):1075-82.

83. Garrett BJ, Caruso JM, Rungcharassaeng K, Farrage JR, Kim JS, Taylor GD. Skeletal effects to the maxilla after rapid maxillary expansion assessed with cone-beam computed tomography. Am J Orthod Dentofacial Orthop. 2008;134(1):8. e1-8. e11.

84. Georgian-Smith D, Moore RH, Halpern E, Yeh ED, Rafferty EA, D'Alessandro HA, Staffa M, Hall DA, McCarthy KA, Kopans DB. Blinded comparison of computer-aided detection with human second reading in screening mammography. AJR Am J Roentgenol. 2007 Nov;189(5):1135-41.

85. Tuğçe U. YAPAY ZEKA VE SAĞLIK UYGULAMALARI. İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 3(1):80-92.

86. Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. Takvim-i Vekayi 2018;6(2):25-36.

87. Turing I. Computing machinery and intelligence-AM Turing. Mind 2007;59(236):433.

88. Arslan K. Eğitimde yapay zekâ ve uygulamaları. Batı Anadolu Eğitim Bilimleri Dergisi 2020;11(1):71-88.

89. Moor J. The Dartmouth College artificial intelligence conference: The next fifty years. Ai Magazine 2006;27(4):87-87.

90. Samuel AL. Some studies in machine learning using the game of checkers. II—Recent progress. IBM J Res Develop. 1967;11(6):601-17.

91. Sen D, Chakrabarti R, Chatterjee S, Grewal D, Manrai K. Artificial intelligence and the radiologist: the future in the Armed Forces Medical Services. BMJ Mil Health. 2020;166(4):254-56.

92. Deo RC. Machine learning in medicine. Circulation. 2015;132(20):1920-30.

93. FAUSETT L. Neural networks based on competition. Fundamentals of Neural Networks: Architectures, Algorithms and Applications. Englewood Cliffs: Prentice-Hall 1994;156-217.

94. Benko A, Lányi CS. History of artificial intelligence. İçinde: Encyclopedia of Information Science and Technology, Second Edition, IGI Global, 2009: 1759-62.

95. Nichols JA, Herbert Chan HW, Baker MA. Machine learning: applications of artificial intelligence to imaging and diagnosis. Biophys Rev. 2019;11(1):111-18.

96. Maltarollo VG, Honório KM, da Silva ABF. Applications of artificial neural networks in chemical problems. Artificial neural networks-architectures and applications 2013;203-23.

97. Başaran E, Cömert Z, Çelik Y. Timpanik Membran Görüntü Özellikleri Kullanılarak Sınıflandırılması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 2021; 33(2):441-453.

98. Öztemel E. Yapay Sinir Ağları, Papatya Yayıncılık, 1. Baskı, İstanbul 2003.

99. Öztemel E. Yapay sinir ağları. Papatya Yayıncılık, 3.Baskı, İstanbul 2012; 52.

100. Serhatlıoğlu S, Hardalaç F. Yapay zeka teknikleri ve radyolojiye uygulanması. Fırat Tıp Dergisi 2009;14(1):1-6.

101. Ağyar Z. Yapay sinir ağlarının kullanım alanları ve bir uygulama. Mühendis ve Makine 2015;56(662):22-23.

102. Kabalcı E. Yapay Sinir Ağları. Ders Notları. 2014.

103. Kaynar O, Görmez Y, Yıldız M, Albayrak A. In *Makine öğrenmesi yöntemleri ile Duygu Analizi*. International Artificial Intelligence and Data Processing Symposium (IDAP'16) 2016;17-18.

104. Efe MÖ, Kaynak O. A Comparative Study of Neural Network Structures in Indentification of Nonlinear Systems Mechatronics 1999;9(3):287-300.

105. Asilkan Ö, IRMAK AGS. İkinci el otomobillerin gelecekteki fiyatlarinin yapay sinir ağlari ile tahmin edilmesi. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 2009;14(2):375-91.

106. Deng L, Yu D. Deep learning: methods and applications. Foundations and trends® in signal processing 2014;7(3–4):197-387.

107. European Society of Radiology (ESR). What the radiologist should know about artificial intelligence - an ESR white paper. Insights Imaging. 2019 Apr 4;10(1):44.

108. Suzuki K. Overview of deep learning in medical imaging. Radiol Phys Technol. 2017;10(3):257-73.

109. Baydilli YY. Derin Öğrenme Yöntemleri ile Periferik Yayma Görüntülerinin Analizi ve Sınıflandırılması. Karabük Üniversitesi Doktora Tezi 2020;11.

110. Brotchie P. Machine learning in radiology. J Med Imaging Radiat Oncol. 2019 Feb;63(1):25-26.

111. Lee J-G, Jun S, Cho Y-W, Lee H, Kim GB, Seo JB, Kim N. Deep learning in medical imaging: general overview. Korean J Radiol. 2017;18(4):570-84.

112. Hwang J-J, Jung Y-H, Cho B-H, Heo M-S. An overview of deep learning in the field of dentistry. Imaging Sci Dent. 2019;49(1):1-7.

113. Koushik J. Understanding convolutional neural networks. CoRR, 2016; 09081.

114. Liu YH In *Feature extraction and image recognition with convolutional neural networks*, Journal of Physics: Conference Series, IOP Publishing: 2018; 062032.

115. Kim P. Matlab deep learning. With machine learning, neural networks and artificial intelligence 2017;130(21).

116. Özkan İ, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi 2017;6(3):85-104.

117. ZahediNasab R, Mohseni H. Neuroevolutionary based convolutional neural network with adaptive activation functions. Neurocomputing 2020;381306-13.

118. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, Dörfer C, Schwendicke F. Deep learning for the radiographic detection of periodontal bone loss. Sci Rep. 2019;9(1):1-6.

119. Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, Lee C-H. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. Sci Rep. 2019;9(1):1-11.

120. Orhan K, Bayrakdar I, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. Int Endod J. 2020;53(5):680-89.

121. Cantu AG, Gehrung S, Krois J, Chaurasia A, Rossi JG, Gaudin R, Elhennawy K, Schwendicke F. Detecting caries lesions of different radiographic extension on bitewings using deep learning. J Dent. 2020 Sep;100:103425.

122. Askar H, Krois J, Rohrer C, Mertens S, Elhennawy K, Ottolenghi L, Mazur M, Paris S, Schwendicke F. Detecting white spot lesions on dental photography using deep learning: A pilot study. J Dent. 2021;107103615.

123. Ruppin J, Popovic A, Strauss M, Spüntrup E, Steiner A, Stoll C. Evaluation of the accuracy of three different computer-aided surgery systems in dental implantology: optical tracking vs. stereolithographic splint systems. Clin Oral Implants Res. 2008;19(7):709-16.

124. Widmann G. Image-guided surgery and medical robotics in the cranial area. Biomed Imaging Interv J. 2007 Jan;3(1):e11.

125. Orhan K, Bilgir E, Bayrakdar IS, Ezhov M, Gusarev M, Shumilov E. Evaluation of artificial intelligence for detecting impacted third molars on cone-beam computed tomography scans. J Stomatol Oral Maxillofac Surg. 2021;122(4):333-37.

126. Yoo J-H, Yeom H-G, Shin W, Yun JP, Lee JH, Jeong SH, Lim HJ, Lee J, Kim BC. Deep learning based prediction of extraction difficulty for mandibular third molars. Sci Rep. 2021;11(1):1-9.

127. Furman E, Jasinevicius TR, Bissada NF, Victoroff KZ, Skillicorn R, Buchner M. Virtual reality distraction for pain control during periodontal scaling and root planing procedures. J Am Dent Assoc. 2009;140(12):1508-16.

128. Lee J-H, Kim D-h, Jeong S-N, Choi S-H. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. J Periodontal Implant Sci. 2018;48(2):114-23.

129. Kurt Bayrakdar S, Orhan K, Bayrakdar IS, Bilgir E, Ezhov M, Gusarev M, Shumilov E. A deep learning approach for dental implant planning in cone-beam computed tomography images. BMC Med Imaging. 2021;21(1):1-9.

130. Yu H, Cho S, Kim M, Kim W, Kim J, Choi J. Automated skeletal classification with lateral cephalometry based on artificial intelligence. J Dent Res. 2020;99(3):249-56.

131. Choi H-I, Jung S-K, Baek S-H, Lim WH, Ahn S-J, Yang I-H, Kim T-W. Artificial intelligent model with neural network machine learning for the diagnosis of orthognathic surgery. J Craniofac Surg. 2019;30(7):1986-89.

132. Ao Y, Wu H. Feature Aggregation and Refinement Network for 2D Anatomical landmark detection. J Digit Imaging. 2022;1-15.

133. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. 3rd International Conference on Learning Representations 2015;1-14.

134. He K, Zhang X, Ren S, Sun J. *Deep residual learning for image recognition*. In Proceedings of the IEEE conference on computer vision and pattern recognition. 2016; 770-778.

135. Huang G, Liu Z, Pleiss G, Maaten LV, Weinberger KQ. Convolutional Networks with Dense Connectivity. IEEE Trans Pattern Anal Mach Intell. 2022 Dec;44(12):8704-8716.

136. Uğurlu M. Performance of a Convolutional Neural Network-Based Artificial Intelligence Algorithm for Automatic Cephalometric Landmark Detection. Turk J Orthod. 2022;35(2):94.

137. Aşçi E, Kiliç M, Çelik Ö, Bayrakdar İŞ, Bilgir E, Aslan AF, Odabaş A, Orhan K. Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zekâ Yöntemi ile Panoramik Radyografilerde Dental Restorasyonların Otomatik Tespiti ve Sınıflandırılması: Metodolojik Çalışmalar. Turkiye Klinikleri. Dishekimligi Bilimleri Dergisi 2022;28(2):329-37.

138. Cook AH, Sellke TA, BeGole EA. The variability and reliability of two maxillary and mandibular superimposition techniques. Part II. Am J Orthod Dentofacial Orthop. 1994;106(5):463-71.

139. Tiulpin A, Thevenot J, Rahtu E, Lehenkari P, Saarakkala S. Automatic knee osteoarthritis diagnosis from plain radiographs: a deep learning-based approach. Sci Rep. 2018;8(1):1-10.

140. Casalegno F, Newton T, Daher R, Abdelaziz M, Lodi-Rizzini A, Schürmann F, Krejci I, Markram H. Caries detection with near-infrared transillumination using deep learning. J Dent Res. 2019;98(11):1227-33.

141. Bruntz LQ, Palomo JM, Baden S, Hans MG. A comparison of scanned lateral cephalograms with corresponding original radiographs. Am J Orthod Dentofacial Orthop. 2006;130(3):340-48.

142. Erkan M, Gurel HG, Nur M, Demirel B. Reliability of four different computerized cephalometric analysis programs. Eur J Orthod. 2012;34(3):318-21.

143. Hwang H-W, Moon J-H, Kim M-G, Donatelli RE, Lee S-J. Evaluation of automated cephalometric analysis based on the latest deep learning method. Angle Orthod. 2021;91(3):329-35.

144. Moon J-H, Hwang H-W, Yu Y, Kim M-G, Donatelli RE, Lee S-J. How much deep learning is enough for automatic identification to be reliable? A cephalometric example. Angle Orthod. 2020;90(6):823-30.

145. Ulkur F, Ozdemir F, Germec-Cakan D, Kaspar EC. Landmark errors on posteroanterior cephalograms. Am J Orthod Dentofacial Orthop. 2016;150(2):324-31.

146. Major PW, Johnson DE, Hesse KL, Glover KE. Landmark identification error in posterior anterior cephalometrics. Angle Orthod. 1994;64(6):447-54.

147. Shokri A, Miresmaeili A, Farhadian N, Falah-Kooshki S, Amini P, Mollaie N. Effect of changing the head position on accuracy of transverse measurements of the maxillofacial region made on cone beam computed tomography and conventional posterior-anterior cephalograms. Dentomaxillofac Radiol. 2017;46(5):20160180.

148. Kim M-J, Liu Y, Oh SH, Ahn H-W, Kim S-H, Nelson G. Evaluation of a multi-stage convolutional neural network-based fully automated landmark identification system using cone-beam computed tomography-synthesized posteroanterior cephalometric images. Korean J Orthod. 2021;51(2):77-85.

149. Lee J-H, Yu H-J, Kim M-j, Kim J-W, Choi J. Automated cephalometric landmark detection with confidence regions using Bayesian convolutional neural networks. BMC Oral Health. 2020;20(1):1-10.

150. Kim J, Kim I, Kim YJ, Kim M, Cho JH, Hong M, Kang KH, Lim SH, Kim SJ, Kim YH, Kim N, Sung SJ, Baek SH. Accuracy of automated identification of lateral cephalometric landmarks using cascade convolutional neural networks on lateral cephalograms from nationwide multi-centres. Orthod Craniofac Res. 2021 Dec;24 Suppl 2:59-67.

151. Hwang H-W, Park J-H, Moon J-H, Yu Y, Kim H, Her S-B, Srinivasan G, Aljanabi MNA, Donatelli RE, Lee S-J. Automated identification of cephalometric landmarks: Part 2-Might it be better than human? Angle Orthod. 2020;90(1):69-76.

152. Park J-H, Hwang H-W, Moon J-H, Yu Y, Kim H, Her S-B, Srinivasan G, Aljanabi MNA, Donatelli RE, Lee S-J. Automated identification of cephalometric landmarks: Part 1—Comparisons between the latest deep-learning methods YOLOV3 and SSD. Angle Orthod. 2019;89(6):903-09.

153. Gil S-M, Kim I, Cho J-H, Hong M, Kim M, Kim S-J, Kim Y-J, Kim YH, Lim S-H, Sung SJ. 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. Am J Orthod Dentofacial Orthop. 2022;161(4):e361-e71.

154. Takeda S, Mine Y, Yoshimi Y, Ito S, Tanimoto K, Murayama T. Landmark annotation and mandibular lateral deviation analysis of posteroanterior cephalograms using a convolutional neural network. J Dent Sci. 2021;16(3):957-63.

EKLER

EK-1. ÖZGEÇMİŞ

1. KİŞİSEL BİLGİLER

Adı Soyadı: Gizem Gözde ÖZŞAHİN

2. EĞİTİM

3. AKADEMİK DENEYİM

4. ÇALIŞMA ALANLARI

5. SON BEŞ YILDAKİ ÖNEMLİ YAYINLAR

EK-2. ETİK KURUL ONAYI

T.C.
ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığı

Sayı : E-25403353-050.99-
Konu : 2021 - 400 Karar

Sayın Dr.Öğr.Üy.Mehmet UĞURLU
Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi
Ortodonti Anabilim Dalı

Karar Tarihi: 15.02.2022
Karar Sayısı: 11

Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı öğretim üyesi Dr.Öğr.Üy.Mehmet UĞURLU'nun sorumluluğunda yürütülecek olan ***"Konik Işınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Posteroanterior Sefalometrik (frontal) Görüntüler Üzerinde Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometrik Noktaların Tespiti"*** başlıklı araştırmanın/çalışmamn gerçekleştirilmesinde etik ve bilimsel açıdan sakınca bulunmadığına karar verilmiştir.

Bilgilerinizi ve gereğini saygı ile rica ederim.

Prof. Dr. Merih ÖZGEN
Kurul Başkanı

Ek: e-imzalı Etik Kurul Kararı

Adres : Meşelik Kampüsü 26040 Odunpazarı
Telefon : 0222 2393750 Faks: 0222 2291418
İnternet Adresi : www.ogu.edu.tr
KEP adresi : esk.osmangaziunirek@hs01.kep.tr

Bilgi için : Ceren KESKİNER
Telefon : 0 222 239 29 79-4690
E-posta : ckeskiner@ogu.edu.tr

Prof.Dr.Merih ÖZGEN
(Başkan)
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
Fizik Tedavi ve Rehabilitasyon AD

Prof.Dr.Hava ÜSKÜDAR TEKE
(Başkan Yardımcısı)
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
İç Hastalıkları AD / Hematoloji BD

Doç.Dr.Ferdi KÖŞGER
(Raportör)
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
Ruh Sağlığı ve Hastalıkları AD

Prof.Dr.Ömür ŞAYLIGİL
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi Tıp Tarihi ve Etik AD

Prof.Dr.Setenay DİNÇER ÖNER
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi Biyoistatistik AD

Prof.Dr.Özlem ÖRSAL
Eskişehir Osmangazi Üniversitesi
Sağlık Bilimleri Fakültesi
Halk Sağlığı Hemşireliği AD

Prof.Dr.Suzan ŞAYLISOY
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi Radyoloji AD

Doç.Dr.Göknur YORULMAZ
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
İç Hastalıkları AD / Endokrinoloji ve Metabolizma Hastalıkları BD

Doç.Dr.Muhammed Fatih ÖNSÜZ
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi Halk Sağlığı AD

Doç.Dr.Melih VELİPAŞAOĞLU
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
Kadın Hastalıkları ve Doğum AD

Doç.Dr.Zeren BARIŞ
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
Çocuk Sağlığı ve Hastalıkları AD / Çocuk Gastroenterolojisi BD

Doç.Dr.Mustafa Değer BİLGEÇ
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi Göz Hastalıkları AD

Doç.Dr. Ömür DERECİ
Eskişehir Osmangazi Üniversitesi
Diş Hekimliği Fakültesi Ağız, Diş ve Çene Cerrahisi AD

Dr.Öğr.Üy.F.Nazlı DURMAZ ÇELİK
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi Nöroloji AD

Av. Önder CAN
Avukat

Etik Kurul Sekreterliği
Ceren KESKİNER
Tel: 0 222 239 29 79 / **4690-91**

T.C.
ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ
GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU BAŞKANLIĞI

KARAR FORMU

Başvuru Tarihi: 14.10.2021	**Çalışmanın Başlığı:** *ESKİ ADI:"Posteroanterior (frontal) Sefalometrik Analiza Açısal ve Boyutsal Ölçümlerin Yapay Zeka Yöntemleri il Tespiti ve Karşılaştırılması"* *YENİ ADI:"Konik Işınlı Bilgisayarlı Tomogra Görüntülerinden Elde Edilen Posteroanterior Sefalometri (frontal) Görüntüler Üzerinde Derin Öğrenme Yöntemiyl Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometri Noktaların Tespiti"* **Çalışmacılar:** Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültes Ortodonti Anabilim Dalı - Dr.Öğr.Üy.Mehmet UĞURLU (Te Danışmanı), Arş.Gör.Gizem Gözde ÖZŞAHİN (Tez Sahibi)
Çalışmanın değerlendirildiği ilk toplantı tarihi: 26.10.2021	**Sonuç:** 1. Kişisel sağlık verileri kimliği belirli veya belirlenebili gerçek kişiye ilişkin her türlü sağlık bilgisi olduğundar kişisel sağlık verilerinin işlenmesi ile ilgili olarak ilgi mevzuat hükümleri dikkate alınmalı, verilerin yetkisi kişilerin eline geçmesi önlenmelidir. Araştırmacıları kurulumuza taahhütnamelerle iletmiş olduklar sorumlulukları yerine getirmeleri beklenmektedir. 2. Kurum izinlerinin alınması araştırmacıları sorumluluğunda olup, ilgili kurumdan alınan izi yazılarının kurulumuza iletilmesi gerekmektedir.
Karar Tarihi: 26.10.2021 **Karar No:** 53	Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültes Ortodonti Anabilim Dalı öğretim üyesi Dr.Öğr.Üy.Mehme UĞURLU'nun sorumluluğunda yürütülecek ola ***"Posteroanterior (frontal) Sefalometrik Analizde Açısal v Boyutsal Ölçümlerin Yapay Zeka Yöntemleri ile Tespiti v Karşılaştırılması"*** başlıklı araştırma/çalışma gereç, amac yaklaşım ve yöntemleri dikkatc alınarak incelenmiş ve uygu bulunmuş olup, araştırmanın/çalışmanın gerçekleştirilmesind etik ve bilimsel yönden sakınca bulunmadığına oy birliği il karar verilmiştir. Araştırmacılara başarılar dileriz.

T.C.
ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ
GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU BAŞKANLIĞI

Çalışmanın Başlığı: *"Konik Işınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Posteroanterior Sefalometrik (frontal) Görüntüler Üzerinde Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometrik Noktaların Tespiti"*

Çalışmacılardan gelen düzeltme metni tarihi: 20.01.2022	Görevi yürütecek araştırıcı olduğum 26.10.2021 tarihinde onaylanan **'Posteroanterior (frontal) Sefalometrik Analizde Açısal ve Boyutsal Ölçümlerin Yapay Zeka Yöntemleri ile Tespiti ve Karşılaştırılması'** isimli projenin adının **'Konik Işınlı Bilgisayarlı Tomografi görüntülerinden elde edilen posteroanterior sefalometrik (frontal) görüntüler üzerinde derin öğrenme yöntemiyle geliştirilmiş yapay zeka algoritmalarıyla sefalometrik noktaların tespiti'** olarak değiştirilmesini talep ediyorum. Gereğini arz ederim.
Çalışmanın değerlendirildiği ikinci toplantı tarihi: 15.02.2022	**Sonuç:** Etik Kurulumuz tarafından 26.10.2021 tarih ve 53 sayılı karar ile olumlu bulunan ***"Posteroanterior (frontal) Sefalometrik Analizde Açısal ve Boyutsal Ölçümlerin Yapay Zeka Yöntemleri ile Tespiti ve Karşılaştırılması"*** başlıklı çalışmanın başlığının ***"Konik Işınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Posteroanterior Sefalometrik (frontal) Görüntüler Üzerinde Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometrik Noktaların Tespiti"*** olarak değiştirilmesi ile ilgili yazınız uygun bulunmuştur.
Karar Tarihi: 15.02.2022 **Karar No:**11	Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı öğretim üyesi Dr.Öğr.Üy.Mehmet UĞURLU'nun sorumluluğunda yürütülecek olan ***"Konik Işınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Posteroanterior Sefalometrik (frontal) Görüntüler Üzerinde Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometrik Noktaların Tespiti"*** başlıklı araştırma/çalışma gereç, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve uygun bulunmuş olup, araştırmanın/çalışmanın gerçekleştirilmesinde etik ve bilimsel yönden sakınca bulunmadığına oy birliği ile karar verilmiştir. Araştırmacılara başarılar dileriz.