T.C.
ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN ELDE EDİLEN LATERAL SEFALOMETRİK GÖRÜNTÜLER ÜZERİNDE DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKA ALGORİTMALARIYLA SEFALOMETRİK NOKTALARIN TESPİTİ

Seda Saliha Kayrak

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 LATERAL SEFALOMETRİK GÖRÜNTÜLER ÜZERİNDE DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKA ALGORİTMALARIYLA SEFALOMETRİK NOKTALARIN TESPİTİ

Seda Saliha Kayrak

Tez Savunma Tarihi: 02.01.2023

Tez Danışmanı: Dr. Öğ. 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 LATERAL SEFALOMETRİK GÖRÜNTÜLER ÜZERİNDE DERİN ÖĞRENME YÖNTEMİYLE GELİŞTİRİLMİŞ YAPAY ZEKA ALGORİTMALARIYLA SEFALOMETRİK NOKTALARIN TESPİTİ**" başlıklı araştırmayı danışmanım Dr. Öğ. Üy.Mehmet Uğurlu'nun rehberlik ve sorumluluğunda tamamladığım; çalışma protokolü ve 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.

Seda Saliha KAYRAK

İÇİNDEKİLER

TEŞEKKÜR ..... **III**

ÖZET ..... **IV**

ABSTRACT ..... **V**

SİMGELER VE KISALTMALAR DİZİNİ ..... **VI**

ŞEKİLLER DİZİNİ ..... **VII**

TABLOLAR DİZİNİ ..... **VIII**

1.GİRİŞ **1**

2.GENEL BİLGİLER **3**

2.1. Sefalometrinin Tarihçesi 3

2.2. Lateral Sefalometrik Radyografi 4

2.2.1. Lateral Sefalometrik Radyografi Kullanım Nedenleri 4

2.3. 3B Görüntüleme Teknikleri 5

2.3.1. Manyetik Rezonans Görüntüleme (MRG) 5

2.3.2. Bilgisayarlı Tomografi 6

2.3.3. Konik Işınlı Bilgisayarlı Tomografi 7

2.4. Üç boyutlu görüntülemenin Ortodontide kullanım alanları 8

2.4.1. Gömülü Dişlerin Görüntülenmesi 8

2.4.2. Kök Rezorpsiyonunun Değerlendirilmesi 9

2.4.3. Temporomandibular Eklemdeki Yıkıcı Etkilerin Değerlendirilmesi 9

2.4.4. Dudak-Damak Yarıklarının Değerlendirilmesi 9

2.4.5. Asimetrinin değerlendirilmesi 10

2.4.6. Solunum yollarının değerlendirilmesi 10

2.4.7. Kraniyofasiyal yapıların değerlendirilmesi 10

2.5. Lateral Sefalometrik Analiz Yöntemleri 11

2.6. Bilgisayar Destekli Dijital sefalometrik analiz yöntemleri 11

2.6.1. Bilgisayar destekli Dijital Sefalometrik Analiz Yazılımları 12

2.7. Yapay Zeka Nedir? 13

2.8. Makine Öğrenmesi 15

2.9. Yapay sinir ağları (artificial neural network-ANN) 15

2.9.1. Yapay sinir ağlarının özellikleri 17
2.9.2. Yapay Sinir Ağı Modelleri 18
2.10. Derin öğrenme ve Derin Evrişimli Sinir Ağları 21
2.11. Evrişimli Sinir Ağı Katmanları 23
2.11.1.Giriş Katmanı 23
2.11.2. Evrişim Katmanı 23
2.11.3. Havuzlama Katmanı 24
2.11.4.Tam Bağlı Katman 24
2.11.5. Sınıflandırma Katmanı 24
2.12. Evrişimsel Sinir Ağlarının Eğitilmesi 25
2.13. Aktivasyon Fonksiyonu 25
2.14. Transfer Öğrenme 25
2.15. Diş Hekimliğinde Yapay Zeka Ve Kullanım Alanları 26
2.15.1. Ortodonti Alanında Yapay Zeka 26
3. MATERYAL VE METOT 28
3.1. Hasta Seçimi 28
3.2. Sefalometrik Radyograf Veri Setinin Oluşturulması 28
3.3. Veri etiketleme 30
3.4. Sefalometrik Radyograflar Üzerinde İşaretlenen Referans Noktaları 31
3.4.1. Yumuşak Doku İşaret Noktaları 31
3.4.2. İskeletsel İşaret Noktaları 32
3.4.3. Dental İşaret Noktaları 34
3.5. Derin Öğrenme Mimarisi 35
3.8. Model Performansının Değerlendirilmesi 40
4. BULGULAR 41
5. TARTIŞMA 47
6. SONUÇLAR VE ÖNERİLER 55
KAYNAKLAR 56
EKLER 63
EK-1. ÖZGEÇMİŞ 63
EK-2. ETİK KURUL ONAYI 64

TEŞEKKÜR

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

Eğitimime önemli katkılarda bulunan, destekleri ve anlayışıyla her zaman yanımızda olan sevgili hocalarım Doç. Dr. İlhan Metin DAĞSUYU'na, Doç. Dr. Rıdvan OKŞAYAN'a ve Dr. Öğr. Üyesi Fatih KAHRAMAN'a

Asistanlığım boyunca çok şey paylaştığım, hepsini ayrı ayrı çok sevdiğim ve beraber çalışmaktan mutlu olduğum arkadaşlarım Mehmet AYDIN, Simge SOYDAN, Melek KULAK, Hüseyin KARA, Jeyhun JAFARLI, Gizem Gözde ÖZŞAHİN, İrem BALCI, Batuhan KULELİ, Zeki ARSLAN, Bircan KABUKÇU, Rabia TÜRK, Taylan ÇELİK, Kerimcan AKTAŞ'a

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

Desteğini her zaman hissettiğim canım arkadaşlarım Ezgi YILMAZ, Ahsen ALANOĞLU, Aslı ATEŞ, Gökçe DURNA, Fazilet ÖZDEMİR ve Hilal ÖĞÜNÇ'e

Üzerimde sonsuz emek ve destekleri olan, her zaman sevgilerini hissettiğim canım annem Şükran KAYRAK'a ve babam Metin KAYRAK'A, her koşulda yanımda olan canım kardeşlerim Emir KAYRAK ve Harun Eren KAYRAK'a çok teşekkür ederim.

ÖZET

Konik Işınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Lateral Sefalometrik Görüntüler Üzerinde Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometrik Noktaların Tespiti

Amaç: Günümüzde insan beyninin işleyişini taklit etme ilkelerine dayanan yeni teknolojiler geliştirilmiştir. Bunlar esas olarak yapay zeka (AI) teknolojilerine dayanmaktadır. Bu araştırmanın amacı, özel bir yapay zeka (AI) algoritması kullanarak yapılan sefalometrik landmark tespitinin başarısını araştırmaktır. Çalışmamızda ortodontik landmark tayininde oluşabilecek gözlemciler arası farkların ve gözlemcilerin farklı zamanlardaki değerlendirmelerinde gözlenebilecek tutarsızlıkların özel bir yapay zeka algoritması kullanılarak yapılan hataların minimuma indirilmesini amaçladık.

Materyal ve Metod: Veri seti hastaların tedavi öncesi alınan KIBT görüntülerinden elde edilmiş sefalometrik radyograf görüntüsünden oluşan çalışmamızda Pytorch mimarisinin radyograflar üzerinde ortodontik ölçüm tayininde kullanılan iskeletsel, dişsel ve yumuşak doku noktalarını belirlemedeki başarısını karşılaştırdık. Görüntüler üzerinde sefalometrik noktalrın etiketlenmesi CranioCatch etiketleme yazılımı (CranioCatch, Eskişehir, Türkiye) kullanılarak yapıldı. AI modelinin eğitimi, PyTorch uygulanan CNN tabanlı derin öğrenme yöntemi ile 300 Epoch kullanılarak gerçekleştirildi. Modelin öğrenme oranı 0.0001 olarak belirlendi.

Bulgular: En yüksek SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm ile Columella(Cm), Mandibular 1.moların mesiali(Md6m) ve Yumuşak doku B(B') noktasından sırasıyla 100, 100, 100 ve 100 olarak elde edildi. Cm'nin MRE ± SD değeri 0.78 ± 0.41, Md6m'nin MRE±SD değeri 0,74±0,38 ve B'nin MRE ± SD değeri 0,72±0.38 olarak bulundu. En düşük SDR puanı olan 2 mm, 2,5 mm, 3 mm ve 4 mm Pterygoid(Pt) noktasından sırasıyla 65,2, 77.8, 85.2 ve 94.7 olarak elde edildi. Pt'nun MRE ± SD değeri 1.731±1.17 olarak bulundu.

Sonuç: İleriki dönemlerde yapılacak olan derin öğrenme altyapılı KIBT raporlama programlarının gelişmesi bakımından çalışmamız çok önemlidir. Bu programların rutin klinik uygulamalarda hekimlere zaman kazandırarak karar destek sistemi rolü olacağını öngörmekteyiz.

Anahtar Kelimeler; Derin öğrenme, Konik ışınlı bilgisayarlı tomografi, Ortodontik ölçüm, Sefalometri, Yapay zekâ

ABSTRACT

Determınatıon Of Cephalometrıc Poınts Wıth Artıfıcıal Intellıgence Algorıthms Developed By Deep Learnıng On Lateral Cephalometrıc Images Obtaıned From Conıc-Beam Computer Tomography Images

Aim: Today, new technologies have been developed based on the principles of imitating the functioning of the human brain. These are mainly based on artificial intelligence (AI) technologies. The aim of this research is to investigate the success of cephalometric landmark detection using a special artificial intelligence (AI) algorithm. In our study, it is aimed to minimize the errors made by using a special artificial intelligence algorithm for the differences between observers that may occur in the determination of orthodontic landmarks and the inconsistencies that can be observed in the evaluations of the observers at different times.

Material and Method: In our study, whose data set consists of cephalometric radiograph images obtained from CBCT images of patients before treatment, the success of Pytorch architecture in determining the skeletal, dental and soft tissue points used in the determination of orthodontic measurements on radiographs was compared. Labeling of cephalometric points on images was done using CranioCatch labeling software (CranioCatch, Eskişehir, Turkey). The training of the AI 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: The highest SDR score of 2 mm, 2.5 mm, 3 mm and 4 mm was obtained from Columella (Cm), Mandibular 1st molar mesial (Md6m) and Soft tissue B(B') points as 100, 100, 100 and 100, respectively. The MRE ± SD of Cm was 0.78 ± 0.41, the MRE±SD of Md6m was 0.74±0.38, and the MRE ± SD of B was 0.72±0.38. The lowest SDR score was obtained from the 2 mm, 2.5 mm, 3 mm and 4 mm Pterygoid(Pt) points as 65.2, 77.8, 85.2 and 94.7, respectively. MRE ± SD of Pt was found to be 1.731±1.17.

Conclusion: Our study is very important in terms of the development of CBCT reporting programs with deep learning infrastructure to be made in the future. We anticipate that these programs will have a role in decision support system by saving time for physicians in routine clinical practices.

Keywords: Artificial intelligence, Cephalometry, Cone-beam computed tomography, Deep learning, Orthodontic measurement.

SİMGELER VE KISALTMALAR DİZİNİ

% : Yüzde
2B : İki Boyutlu
3B : Üç Boyutlu
AI : Yapay Zekâ (Artificial Intelligence)
ANN : Yapay Sinir Ağları (Artificial Neural Networks)
Ark. : Arkadaşları
AUC : Area Under Curve
CNN : Evrişimli Sinir Ağları (Convolutional Neural Networks)
BT : Bilgisayarlı Tomografi
DCNN : Derin Evrişimli Sinir Ağları (Deep Convolutional Neural Networks)
DICOM : Digital Imaging and Communications in Medicine
DL : Derin Öğrenme (Deep Learning)
FCN : Tamamen Bağlı Ağ (Fully Connected Network)
FDI : Federation Dentaire Internationale
FN : Yanlış Negatif (False Negative)
FP : Yanlış Pozitif (False Positive)
KIBT : Konik Işınlı Bilgisayarlı Tomografi
Kv : Kilovolt
mA : Miliamper
MIT : Massachusetts Institute of Technology
ML : Makine Öğrenmesi (Machine Learning)
MÖ : Milattan Önce

ŞEKİLLER DİZİNİ

Şekil No **Sayfa No**

Şekil 2.1 Yapay zekanın temel kavramları [37] 14
Şekil 2.2 Biyolojik sinir hücresi ve yapay sinir ağı[42] 16
Şekil 2.3 Yapay sinir ağı modeli[44] 17
Şekil 2.4 Tek katmanlı algılayıcı modeli[49] 19
Şekil 2.5 Çok katmanlı algılayıcı modeli[49] 20
Şekil 2.6 a) Makine öğrenmesi ve b) derin öğrenme.[52] 22
Şekil 2.7 DCNN mimarisi[54] 23
Şekil 2.8 Evrişim işlemi[55] 23
Şekil 2.9 Havuzlama işlemi[55] 24
Şekil 3.1 KIBT görüntüsünün dışa aktarımı 29
Şekil 3.2 Baş pozisyonunun ayarlanması .....**Hata! Yer işareti tanımlanmamış.**
Şekil 3.3 Dolphin İmaging programında sefalometrik radyograf oluşturulması 29
Şekil 3.4 Özellik toplama ve iyileştirme ağının (FARNet) mimarisi. FARNet, bir omurga ağı, çok ölçekli bir özellik toplama (MSFA) modülü ve bir özellik iyileştirme (FR) modülü içerir. 35
Şekil 3.5 Farnet mimarisi ile gerçekleştirilen diş tespit modelinin gelişim aşamalarının diyagramı 39
Şekil 4.1 Test sonucu görüntülerinin değerlendirilmesi. (Kırmızı noktalar uzman ortodontistin işaretlediği,Yeşil noktalar yapay zeka uygulamasının işaretlediği noktalar) 44

TABLOLAR DİZİNİ

Şekil No **Sayfa No**

Tablo 2.1 Biyolojik sinir hücresi ve yapay sinir ağı terminolojisi [42] 16

Tablo 3.1 Veri seti sınıflandırılması 38

Tablo 4.1 Sefalometrik nokta tespitinin SDR ve MRE değerleri 44

1. GİRİŞ

Sefalometrik radyografi görüntüleri lateral ve postero-anterior (frontal) sefalometrik radyografi görüntüleri olmak üzere ikiye ayrılmaktadır ve kullanım alanıyla; gelişimin ve morfoloji belirlenmesini, anomalilere tanı konulmasını, tedavi planlamasını, tedavi yapıldıktan sonra sonucun değerlendirilmesini, dişsel yapılar ile kraniyal yapılar arasındaki ilişkinin tespit edilmesini, maloklüzyonun dişsel veya iskeletsel kaynaklımı olduğunun belirlenmesini sağlayan önemli bir klinik metottur.[12]

Sefalometrik analiz öncelikle boyutsal ve açısal ölçümlerin çizim kağıtları üzerinde anatomik noktaların belirlenmesi ardından açı ölçer ve cetvel kullanılarak değerlendirilmesi ile ortaya çıkmıştır.[3]

Teknolojinin gelişmesiyle birlikte bilgisayar sistemleri kullanılarak sefalometrik analiz yapabilmemize olanak sağlayan çeşitli analiz programları geliştirilmiş ve yaygın olarak kullanılmaya başlanmıştır. Bilgisayar destekli sefalometri, radyografideki noktalar direkt olarak işaretlendikten sonra, çok kısa sürede ölçümler yapılabildiğinden dolayı zaman yönünden çok efektif olmaktadır. Bu yöntemle anatomik landmarkların belirlenmesi dışındaki ölçüm hatalarının da azalmasına olanak sağlamaktadır.[1] Yapay zekanın (AI) hızlı gelişimi, mevcut kapsamlı veri kümelerinin analizleri de dahil olmak üzere günlük yaşamın birçok yönüne nüfuz etmiştir. Ortodontik teşhis ve tedavi planlaması ile ilgili olarak, AI teknolojisinin geliştiricileri, sefalometrik radyografi görüntülerinden sefalometrik nokta işaretlerini çok az insan etkileşimi ile otomatik olarak tanımlamayı amaçlamaktadır.[4] Bu araştırmanın amacı, özel bir yapay zeka (AI) algoritması kullanarak yapılan sefalometrik landmark tespitinin başarısını araştırmaktır. Çalışmamızda ortodontik landmark tayininde oluşabilecek landmark tespitini gerçekleştiren

hekimler arası farkların ve hekimlerin farklı zamanlardaki değerlendirmelerinde gözlenebilecek tutarsızlıkların özel bir yapay zeka algoritması kullanılarak yapılan hataların minimuma indirilmesini amaçladık. Sefalometrik radyograflardan veri seti oluşturmak için daha önceden kliniğimize başvurmuş hastaların üç boyutlu radyografik arşiv kayıtlarının kullanılmasını planladık.

2. GENEL BİLGİLER

2.1. Sefalometrinin Tarihçesi

İnsan kraniyofasiyal modellerinin incelenmesine yönelik bilimsel bir yaklaşım ilk olarak, eski kuru kafataslarının çeşitli boyutlarını kaydeden antropologlar ve anatomistler tarafından başlatıldı. Kraniyometri adı verilen osteolojik noktalardan kuru kafatasının ölçümü daha sonra canlı deneklere uygulandı, böylece bir 'boylamsal büyüme çalışması' yapılabildi. Bu tekniğe, canlı bir öznenin başının, üst komşu dokudan palpasyonla veya presleme yoluyla bulunan kemik işaretlerinden ölçülmesine sefalometri denir. Bununla birlikte, ölçümler deri ve yumuşak doku örtüsünden yapıldığı sürece, sefalometrik yöntem hiçbir zaman tam olarak doğru olamaz. 1895 yılında Röntgen tarafından X-ışınlarının keşfi diş hekimliği mesleğinde devrim yarattı. Bir radyografik kafa görüntüsü iki boyutta ölçülebilir, böylece kraniyofasiyal büyüme ve gelişimin doğru bir şekilde incelenmesini mümkün kılar. Radyografik görüntüdeki kemikli ve yumuşak doku işaretlerinin gölgelerinden başın ölçümü, röntgenografik sefalometri olarak bilinir hale geldi (Krogman ve Sassouni, 1957). 1922'de Pacini tarafından bir lateral kafa filmi üretmek için teleroentgenografik bir teknik tanıtıldı. Bu yöntemle, odak-film mesafesi 2 m'ye (78.7 inç) artırılarak görüntünün boyutu küçültüldü, ancak yine de uzun zamanlı maruz kalma süresi boyunca baş hareketinden kaynaklanan bazı bozulmalar vardı.[5]

1931'de ABD'de Broadbent ve Almanya'da Hofrath aynı anda yüksek güçlü bir X-ışını makinesi ve sefalostat veya sefalometre adı verilen bir kafa tutucu kullanarak standartlaştırılmış bir sefalometrik teknik sundu. Ve bu yöntem ile bir sefalometri uygulaması ilk kez ortaya koyulmuş oldu.[6]

2.2. Lateral Sefalometrik Radyografi

Günümüzde ortodonti branşında, ortodontik malokluzyonların teşhisi ve tedavi planı yapılırken klinik muayene bulgularına ilaveten hastanın fotoğrafları ve ağız içi modelleri ve radyografilerden yararlanılmaktadır. Birden fazla sınırlı yönü olmasına rağmen sefalometri önemli bir klinik teşhis yöntemidir.[7]

2.2.1. Lateral Sefalometrik Radyografi Kullanım Nedenleri

Sefalometrik analizler sayesinde ortodontik malokluzyonun dişsel ya da iskeletsel olduğu bulunabilmektedir. Sefalometri çoğu kez öznel olan klinik muayenenin aksine nesnel bir yöntemdir. Ricketts, sefalometrinin bu özelliklerini 4C kuralı ile formüllendirmiştir.[8]

Ricketts'e göre, sefalometrik yöntem:

1. Malokluzyonun anatomik, fizyolojik veya patolojik nedenlerle olup olmadığını morfolojik olarak tanımlayarak karakterize etmektedir (characterised),

2. Başla bireylerde veya aynı bireyin farklı yaş aralıklarında karşılaştırma yapabilme imkanı sağlar (compared),

3. Dental ve iskeletsel yönden çene, kemik veya dişsel düzeyde farklı anatomik durumları sınıflandırır (classified),

4. Bireye, aileye veya diğer hekim arkadaşlarına hekimin klinikte tanımladığı durumu iletir (communicated).[3]

Kraniyofasiyal görüntüleme, dental ve iskelet yapının o anki hali ile ortodontik tedavinin yapacağı değişiklikleri ve bireyin gelişimi sırasında meydana gelecek değişiklikler arasındaki kompleks ilişkinin yorumlanması amacıyla veya aşağıdaki kategorilerin bir veya birkaçının incelenmesi amacıyla kullanılmaktadır.

- Normal ve normal olmayan anatominin tespit edilmesi
- Kökün uzunluğu ve kök hizalarının seçilmesine
- Çene şekli ve gerekli olan diş mesafesi arasındaki ilişkinin belirlenmesi
- Maksillo-mandibular ilişkinin uzaysal olarak tespiti
- TME pozisyonunun belirlenmesi
- Daha önce, şuan ve olması beklenen kraniyofasiyal gelişme boyutunun ve yönünün belirlenmesi
- Kraniyofasiyal yapılarda tedavinin sonuçlarının belirlenmesi
- Fazladan bulunan ve gömülü dişlerin lokalizasyonunun belirlenmesi [9]

2.3. 3B Görüntüleme Teknikleri

2.3.1. Manyetik Rezonans Görüntüleme (MRG)

İlk nükleer manyetik rezonans, 1940'larda keşfedildi ve otuz yıl sonra görüntüleme amacıyla önerildi. O zamandan beri, manyetik rezonans görüntüleme (MRI), tanısal klinik tıp ve biyomedikal araştırmalarda en güçlü tekniklerden biri haline geldi. Günümüzde MRG, öncelikle anatomik görüntüler üretmek için bir teknik olarak kullanılmaktadır, ancak aynı zamanda örneğin hareket ve akış hakkında işlevsel bilgiler

sunar. MRI yumuşak dokuyu ortaya çıkarırken detaylı morfoloji, manyetik rezonans spektroskopisi (MRS) fiziksel-kimyasal durum hakkında bilgi sağlar ve in vivo biyolojik araştırmalarda bir araç olarak kullanışlılığı açıkça ortaya konmuştur.[10]

MRG'nin çalışma prensibi diğer görüntüleme tekniklerinden farklıdır. Örnek olarak BT dokuların radyasyon ışınlarının absorbe gücünü kullanırken MRG doku içerisindeki H2O miktarlarını kullanır. MRG'nin diğer görüntüleme teknilerinde göre en büyük özelliği dokuların iyonize edici ışınlarla karşılaşmamasıdır, dokulardaki farklılıkları belirleyecek görüntü için incelenmek istenen yere radyo dalgaları gönderilmesi ve hidrojen kullanılmasıdır.[11]

Ortodontide MRI kullanımındaki sınırlayıcı faktör (ekonomik maliyet sorununun yanı sıra), bu modalitenin işlevselliği için görüntülenen dokularda çok sayıda hidrojen çekirdeğinin varlığına bağlı olmasıdır. Çünkü kemik gibi sert dokular, mine ve dentin az sayıda serbest hidrojen çekirdeği içerir, bu güçlü tanı aracının kullanımı ortodontide temporomandibular eklemin kıkırdaklı bileşenlerinin görselleştirilmesiyle sınırlıdır.[12]

2.3.2. Bilgisayarlı Tomografi

Görüntüleme teknikleri çoğunlukla ortodontide sınıflandırılmış anatomik yapıların en son durumlarını değerlendirmek için kullanılır. Bu sebeplerden ötürü konvansiyonel radyografi metotları, video ve fotoğraf görüntülerini içeren iki boyutlu görüntüleme metotları geçmiş yıllardan beri ortodonti kayıtlarının bir parçası haline gelmiştir. Bilgisayarlı tomografi (BT) gibi kesitsel görüntüleme teknikleri ise daha çok karar vermesi daha zor problemlerin ortadan kaldırılmasına yardımcı olmak için kullanılmaktadır.[13]

Başlangıçta bir kafa tarayıcısı olarak tasarlanan bilgisayarlı tomografi (BT), geliştirilmesinden bu yana orofasiyal yapıların değerlendirilmesinde kullanılmaktadır. Bununla birlikte, CT makinelerinin diş hekimliği için yüksek maliyetleri, geniş ayak izi ve yüksek radyasyona maruz kalma gibi sınırlamaları vardır.[14]

2.3.3. Konik Işınlı Bilgisayarlı Tomografi

KIBT, iki boyutlu bir detektöre konumlandırılmış koni şekilli X-ışını demetini baz alan görüntü oluşturma tekniğidir. Kaynak dedektör sistemi, bir dizi iki boyutlu görüntü üreten obje etrafında bir rotasyon hareketi gerçekleştirir.[15]

Konik ışınlı görüntüleme (KIBT, koni ışınlı bilgisayarlı tomografi olarak da adlandırılır), tipik olarak panoramik, BT, manyetik rezonans görüntüleme (MRI) ve sintigrafiyi içeren görüntüleme seçeneklerinin donanımını genişletir. Konik ışınlı görüntülemenin özel katkıları öncelikle anatomik olarak karmaşık bir alandaki yapıların ilişkisinin kesin olarak anlaşılmasına, düşük radyasyon almasına ve düşük görüntüleme maliyetine izin veren yüksek uzamsal kemik ve diş çözünürlüğüdür. Konik ışınlı görüntüleme, diş hekimliğinde, yumuşak doku ayrımları gerektiren durumların aksine, dişler ve kemik gibi yüksek kontrastlı nesneleri görüntülemek için kullanılır. Konik ışınlı görüntülerinin yüksek uzaysal çözünürlüğü, diş implantları için tedavi planlaması ve değerlendirme dahil olmak üzere çeşitli uygulamalar için özellikle önemlidir. Konik ışın görüntüleme ile mevcut yüksek uzaysal çözünürlükten yararlanan orofasiyal yapıları içeren çok çeşitli kistler, tümörler, enfeksiyonlar, gelişimsel anomaliler ve travmatik yaralanmalar vardır. Ortodonti için yüz kemikleri büyük görüntü alanları gerektirir ve daha düşük görüntü çözünürlüğünü kabul edebilir. Mevcut birçok DICOM (tıpta dijital görüntüleme ve iletişim; dijital görüntüleri ve ilgili verileri kullanan disiplinlerde biyomedikal teşhis

bilgilerinin iletişim standartları) izleyicilerine ek olarak, çok sayıda uygulamaya özel yazılım aracının sürekli geliştirilmesi diş hekimlerine birçok tanısal konuda eksiksiz çözümler sunar.[14]

KIBT'nin önemli avantajları bulunmasının rağmen bazı dezavantajları da bulunmaktadır. Bu dezavantajların başında görüntü kalitesini zayıflatan artefaktlar gelmektedir. Artefakt, obje ile alakası olmayan hasar anlamına gelir. Artefaktlar çoğunlukla metal restoratif materyaller veya braketler sebebiyle oluşmaktadır. Bu durumlara ek olarak radyasyon dağılımına bağlı görüntünün izlenmesine engel olan dansite değişiklikleri (noise) de oluşabilir. KIBT'nin diğer önemli dezavantajı da yumuşak dokuların görüntülenmesinin sınırlı olmasıdır.[15]

2.4. Üç boyutlu görüntülemenin Ortodontide kullanım alanları

2.4.1. Gömülü Dişlerin Görüntülenmesi

Gömülü dişler, Ortodontinin ilgi alanı olan bir konudur. Çoğunlukla üçüncü molarlar gömülü kalmakla birlikte gömülülükte sırayla maksiler kanin ve maksiler santral dişler gelir. Bu dişlerin pozisyonlarının tam olarak belirlenebilmesi ve çekim endikasyonu verilmişse de cerraha yardımcı olabilmesi için konvansiyonel teknikler yerine KIBT kullanılmaktadır.[16] Ektopik olarak sürmüş veya tam süremeyiş gömülü kanin dişlerin doğru konumlarına alınabilmesi ve yapılacak cerrahi işlemin daha az invaziv olması için de iyi alınmış bir KIBT görüntüsü hem cerraha hem de ortodontiste yol göstermektedir.[17]

2.4.2. Kök Rezorpsiyonunun Değerlendirilmesi

Ortodontik tedavide önemli olan kök rezorpsiyonları periapikal radyografilerde kolayca tespit edilebilmektedir. Ancak dişin lingual ya da bukkal kısmında meydana gelen kök rezorpsiyonunu iki boyutlu görüntülerle değerlendirmek oldukça zor olmaktadır. KIBT herhangi bir dişin herhangi bir yüzeyindeki rezorpsiyon miktarını ayrıntılı bir şekilde görüntülememizi olanak sağlamaktadır.[18]

2.4.3. Temporomandibular Eklemdeki Yıkıcı Etkilerin Değerlendirilmesi

Hastaların ağrı ve disfonksiyon gibi nedenlerde ortodonti kliniğine başvurduğu TME problemleri de konvansiyonel radyografik tekniklerle temporal kemiğin TME'ye yakın olması nedeniyle yeterli düzeyde görüntülenememektedir. Bu konuda da KIBT düşük dozda ve yüksek kalitede görüntüler vermektedir. Ayrıca lateral sefalometrik filmlerde kondil başı ve eklem fossası sadece sagittal olarak görüntülenebilirken, KIBT ile hem frontal hem de aksiyel kesit alınabilir.[19, 20]

2.4.4. Dudak-Damak Yarıklarının Değerlendirilmesi

İki boyutlu radyografi teknikleriyle yüz asimetrisini değerlendirmek oldukça zordur ve bazı problemlere neden olmaktadır. Bu problemlerden başlıcaları görüntülerin süperpoze olması, hasta pozisyonlandırma hataları ve görüntünün distorsyona uğramasıdır. KIBT görüntüleriyle direkt ölçüm yapılıp, kondil ve ramus uzunlukları net şekilde karşılaştırılabilmektedir. KIBT görüntüleri ile mandibuladaki asimetri değerlendirilirken, pozisyonlandırma hataları da en aza indirilmektedir.[21]

2.4.5. Asimetrinin değerlendirilmesi

İki boyutlu radyografilerle yüz asimetrisini değerlendirmek, süperpoze olma, hasta pozisyonlandırma hataları ve görüntünün distorsyona uğraması gibi problemler sebebiyle oldukça zor olmaktadır. KIBT görüntülerinden doğrudan ölçüm yapılarak, kondil ve ramus uzunlukları karşılaştırılabilir. KIBT görüntüleri ile mandibuladaki asimetriyi değerlendirirken, pozisyonlandırma problemleri de giderilebilmektedir.[22]

2.4.6. Solunum yollarının değerlendirilmesi

KIBT kayıtları ile solunum yolunun üç boyutlu görüntüsü elde edilebilir, havayolu ve sinüslerin hacimleri ölçülebilir. Bu yöntemle solunum yolunun en dar bölgesi belirlenebilir ve bu bölgenin aksiyal yöndeki boyutu ölçülebilir.[23]

2.4.7. Kraniyofasiyal yapıların değerlendirilmesi

Geleneksel sefalometrik, görüntü büyütme, sol ve sağ taraf farklılıkları ve kafa konumlandırma ile sonuçlanan x-ışını ışını geometrisi dahil olmak üzere bir dizi faktörle sınırlıdır. Lateral sefalogramların fiziği, ortaya çıkan görüntü üzerinde, bir büyütme hatasını yansıtabilecek önemli kısıtlamalar getirir. Filme yakın olan taraf, filmden uzak olan tarafa göre daha az büyütülür, bu da lateral sefalogramlarda görülebilen mandibula çift sınırına neden olur. KIBT ile büyütme sorunu yoktur, çünkü 3 boyutlu nesne, x-ışınları paralel olmasa bile büyütme faktörünü hesaplama ve ortadan kaldırma yeteneğine sahip matematiksel bir algoritma aracılığıyla ham verilerden yeniden oluşturulur. CBCT tarafından oluşturulan izotropik görüntüler, 3 boyutlu görüntüleme yazılım paketlerinde

bulunan doğrusal ve açısal ölçüm araçları kullanılarak doğrulanabilen asimetri ve anormalliklerin görsel gözlemlerini kolaylaştırır. Bu ölçümler güvenilir ve anatomik olarak doğrudur.[24]

2.5. Lateral Sefalometrik Analiz Yöntemleri

Sefalometrik analiz için en uzun zaman kullanılan yöntemdir. Sefalometrik radyografın üzerine bir asetat tabakası yerleştirmeyi ince uçlu bir kurşun kalem kullanarak sefalometrik noktaları tanımlamayı ve noktaların konumları arasındaki mesafeleri ve açıları ölçmeyi içerir.[25] Bu tekniğin dezavantajı zaman kaybının olması ve sefalometrik hataların sıklıkla görülebilmesidir.[26] Geleneksel olarak konvansiyonel çizilen sefalometrik analizin güvenilirliği hekimin tecrübesi, kullanılan işaretlerin görünebilirliği ve görüntünün yoğunluk ve keskinliği ile de alakalıdır.[27]

2.6. Bilgisayar Destekli Dijital sefalometrik analiz yöntemleri

Teknolojinin gelişmesiyle beraber çizimler bilgisayar üzerinde yapılmaya başlanmıştır. Bu çizimler için geleneksel sefalometrik radyografilerin tarayıcılar yardımı ile dijital halleri oluşturulurulur.[28,29] Dijital ortamdaki sefalometrik radyografi üzerinde referans noktaları işaretlenir ve daha sonra bilgisayar yazılımı, mesafeleri ve açıları otomatik olarak ölçerek sefalometrik analizi tamamlar. Yapılan analiz manuel değil de bilgisayar tarafından gerçekleştirildiği için, araştırmacılar tarafından ölçümler sırasında yapılan hataları azaltarak ve zaman kazandırarak sefalometrik analizin tanısal değerini iyileştirdiği savunulmaktadır.[26] Diğer yandan, referans noktalar araştırmacı tarafından

belirlendiği için geleneksel sefalometrik analiz yöntemine benzeyen hataların bu yöntemde de olabileceği belirtilmiştir.[30]

Bilgisayarlı analiz sistemlerinin zaman içerisinde gelişim göstermiş. Ve bu gösterdiği gelişim sürecine göre birinci, ikinci ve üçüncü kuşak analiz sistemleri olarak sınıflandırılmıştır.

1. Nesil bilgisayar analiz sistemlerinde; geleneksel radyografi görüntülerinin çizimi dijital ortama aktarılıp, sonuçlar yazılım programında ölçülmektedir.

2. Nesil bilgisayar tabanlı analiz sisteminde; Dijital tarayıcılar ve kameralardan elde edilen görüntüler bilgisayar ortamında çizilip ölçümler yapılmaktadır.

3. Nesil bilgisayar tabanlı analiz sistemlerinde;dijital olarak elde edilen radyografiler ışığa duyarlı fosfor plakalar ya da doğrudan dijital sistemler sayesinde direkt bilgisayar ortamında çizimler ve ölçümler yapılmaktadır.[28]

2.6.1. Bilgisayar destekli Dijital Sefalometrik Analiz Yazılımları

Güncel piyasada birçok marka adı altında ticari amaçlı bilgisayar destekli dijital sefalometrik analiz programı vardır: Ceph Smile Plus, Dentrix Image, Dr. Ceph, IOPS, JOE, Niamtu Imaging Systems, Quick ceph 2000, Onyx Ceph, OPAL, Orthoview-Ceph, Dolphin, Prescription Planner/Portrait, Screenceph, T PhotoEze, Nemoceph, Vistadent, Dentofacial Planner.

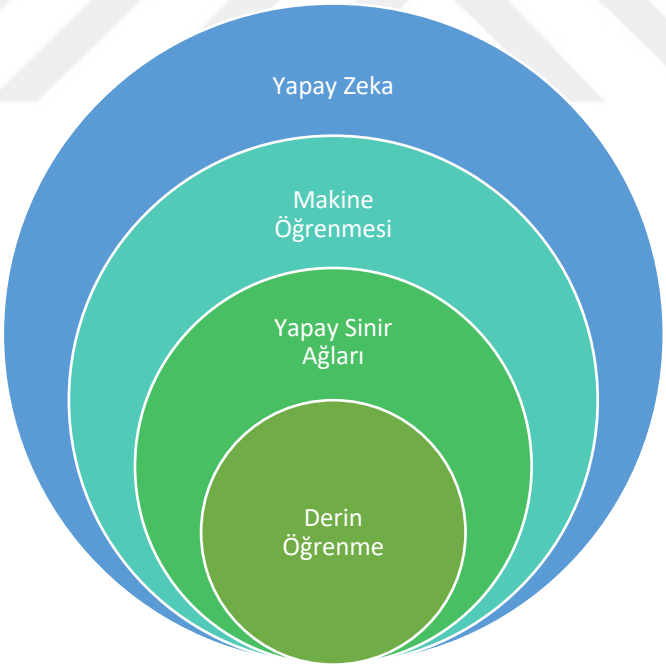
Dijital sefalometrik analiz programlarını kendi içinde ve konvansiyonel yöntemlerle kıyaslayan çalışmalar; İlk referans nokta tahminlerini sağlamak için bu tekniklerin klinik amaçlarla kullanılması çok yardımcı olabilir. Aslında, ortodontistin bilgisayar destekli referans sefalometrik analiz özelliğine sahip otomatik sistemler,

zamandan tasarruf edilmesi ve sefalometrik analizin doğruluğunun artması açısından gelecekte bir avantaj sağlayabileceğini belirtmiştir.[25, 31, 32]

2.7. Yapay Zeka Nedir?

Yapay zeka (AI), 'yaygın olarak akıllı davranış olarak adlandırılan şeyin sayısal olarak anlaşılmasıyla ve bu tür davranışları sergileyen eserlerin yaratılmasıyla ilgilenen bir bilim ve mühendislik alanı' olarak tanımlanır. Aristoteles, kuramları (üç kısımlı tümden gelimli bir akıl yürütme) aracılığıyla 'doğru düşünmeyi' (mantık) resmileştirmeye çalışmış. Modern çağdaki çalışmaların çoğu bundan ilham almış ve zihnin işleyişi üzerine yapılan ilk çalışmalar çağdaş mantıksal düşüncenin kurulmasına yardımcı olmuştur.[33] Bilgisayarların insanları zeki gösterecek şekilde çalışmasını sağlayan programlara yapay akıllı sistemler denir. İngiliz matematikçi Alan Turing (1950), modern bilgisayar biliminin ve yapay zekanın kurucularından biriydi. 1950'de Alan Turing tarafından yapılan araştırma, makinelerin insanlarla aynı düzeyde düşünme yeteneğine sahip olup olmayacağını araştırmaya başladı. Turing, bir makinenin akıllı olup olmadığını belirlemek için kullanılabilecek bir test önerdi. Test artık yapay zekanın temel taşı olarak kabul ediliyor, bu daha sonra 'Turing testi' olarak popüler hale geldi.[34] AI terimi çoğunlukla robotik ile ilişkilidir. İnsan zekasını kolayca taklit edebilen ve belirli faaliyetleri gerçekleştirebilen bir yazılım veya makine geliştirmek için teknolojinin nasıl kullanıldığını açıklar. Bir matematikçi olan John McCarthy, 1955'te yapay zeka terimini ortaya attı ve yaygın olarak yapay zekanın babası olarak kabul edildi. Bu terimi, makinelerin "akıllı" faaliyetler kapsamına girebilecek görevleri gerçekleştirme potansiyelini açıklamak için seçti. 1956 yılında, John McCarthy, resmi olarak yapay zeka araştırma projesi üzerine olan ünlü bir Dartmouth konferansı düzenledi, bu disiplinin

ortaya çıktığı zamandı. Konferans, 1950'lerden 1970'lere kadar, AI üzerinde kapsamlı araştırmaların yapıldığı kritik dönemi ateşledi. Prof. Dr. Cahit Arf, Türkiye'de düzenlenen "Makineler Düşünebilir mi?" başlıklı konferansta bir konuşma yaptı. 1958'de "Bir makine nasıl düşünür?" diye sordu. Profesör Arf, uygulanabilir olduğunu iddia ederek kendi başına düşünebilen bir makine yaratma fikrini örneklendirdi.1978'de uygulamalı bir matematikçi olan Richard Bellman, yapay zekayı, öğrenme, karar verme ve problem çözmeyi içeren insan düşünme yetenekleriyle ilişkili faaliyetlerin otomasyonu olarak tanımladı. Günümüz dünyasında yapay zeka, problem çözme gibi insan bilişsel becerilerini taklit edebilen herhangi bir makine veya teknolojiyi ifade eder.[35] 1950'lerde yapay zeka kavramının ardından, 1980'lerde "makine öğrenimi" kelimesi ortaya çıkmış, bunu derin öğrenme ve yapay sinir ağları takip etmiştir.[35]



Şekil 2.1 Yapay zekanın temel kavramları[35]

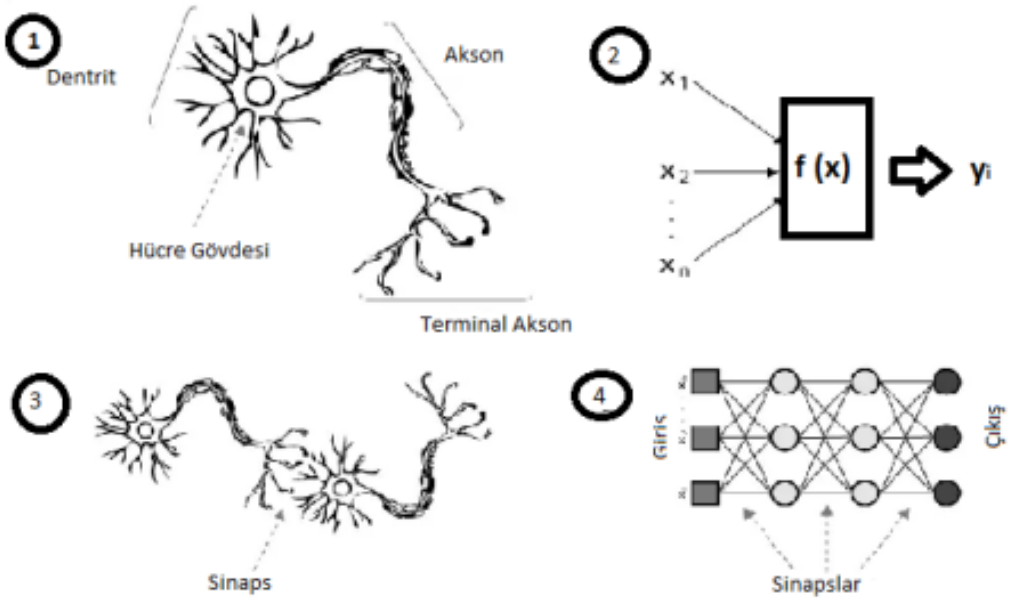
2.8. Makine Öğrenmesi

Yapay zeka teknolojisindeki amaç makinelerin sorunları yüklenen veriler yoluyla çözme yeteneğini kazanmasıdır. Yapay zekayı anlamak için makine öğrenmesi, derin öğrenme ve sinir ağları gibi terimlere aşina olmak gerekir. (Şekil 2.1)

Makine öğrenimi yapay zekanın önemli bir alt başlığıdır ve bir veri kümesine dayalı sonuçları tahmin etmek için algoritmalara dayanan yapay zekanın bir parçasıdır. Makine öğreniminin amacı, sorunları insan girdisi olmadan çözebilmeleri için makinelerin verilerden öğrenmesini kolaylaştırmaktır.[36] Makine öğrenimindeki son ilerlemeler, insan düzeyinde semantik anlayış ve bilgi çıkarma gibi görünen bir şeye ve bazen de soyut kalıpları insan uzmanlardan daha fazla doğrulukla tespit etme becerisine ulaşmıştır.[37]

2.9. Yapay sinir ağları (artificial neural network-ANN)

Son yirmi yıldaki yayın hacmine bakıldığında, YSA tıpta en popüler AI tekniğidir.[38] YSA'lar, biyolojik sinir sisteminden ilham alan hesaplamalı analitik araçlardır. Paralel işlem yapabilen, "nöronlar" adı verilen yüksek düzeyde birbirine bağlı bilgisayar işlemcilerinden oluşan ağlardan oluşurlar.[39] Sinir ağlarının amacı, insan beyni gibi işlev gören sinir ağları oluşturmaktır.[37] Biyolojik sinir hücresi ve yapay sinir ağı benzetmeleri Şekil 1'de verilmiştir. Biyolojik Sinir sistemi birimleri ve yapay sinir sisteminde onlara karşılık gelenler ise Tablo 2.1'de verilmiştir.

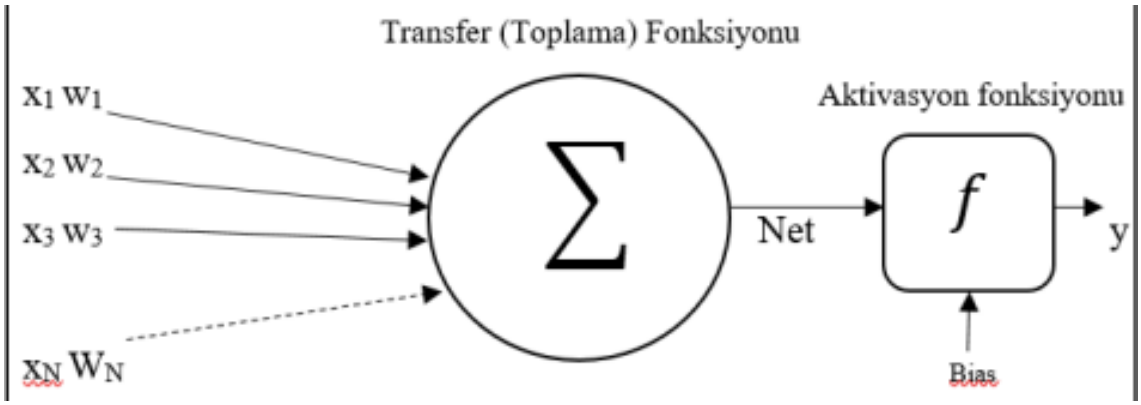


Şekil 2.2 Biyolojik sinir hücresi ve yapay sinir ağı[40]

Tablo 2.1 Biyolojik sinir hücresi ve yapay sinir ağı terminolojisi[40]

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

YSA, birbirine bağlı yapay nöronlardan oluşur. Her yapay nöron, ağırlıklı kanıt toplamına dayalı olarak bir karar sinyali veren basit bir sınıflandırıcı modeli uygular (Şekil 2.2). YSA'yı oluşturmak için bu temel hesaplama birimlerinden yüzlercesi bir araya getirilir. Ağın ağırlıkları, giriş sinyali çiftlerinin ve istenen çıktı kararlarının sunulduğu, beynin belirli görevleri başarmayı öğrenmek için harici duyusal uyaranlara dayandığı durumu taklit eden geri yayılım gibi bir öğrenme algoritması tarafından eğitilir.[41]



Şekil 2.3 Yapay sinir ağı modeli[42]

YSA nöronuna n tane veri girişi olmaktadır(x_1,x_2,x_3…….x_n). Bu girdilere karşılık olarak ağırlık değerleri (w1, w2, w3 … wN) ağ üzerindeki etki değerlerdir. Tüm girdiler ağırlık değerleri ile çarpılarak transfer fonksiyonunda birleştirilerek bias değer de (b) katıldıktan sonra aktivasyon fonksiyonundan geçirilmektedir.[42]

Aktivasyon fonksiyonundan bulunan değer çıkış değeri olarak kabul edilir. Bir yapay sinir hücresinin birden fazla girdisi olmasına karşın bir tane çıktı değeri vardır.[43]

YSA hesaplama modellerini insan beyni sinapslarının ve nörunun mimarisini öğrenerek hesaplama birimlerini modeller.[41] YSA'nın hesaplama gücü, bağlantıların ağırlıkların güncellenmesini olanak sağlayan eğitim veri setlerinin miktarına ve kalitesine bağlıdır.[44,45] Ağırlıklar veri setlerinin arasında en elverişli olan değeri bulmaya çalışır ve böylece YSA'nın eğitimi gerçekleşir.[46]

2.9.1. Yapay sinir ağlarının özellikleri

Yapay sinir ağlarının çeşitli temel özellikleri vardır:[40]

- Doğrusal Olmama
- Paralel Çalışma

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

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

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

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

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

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

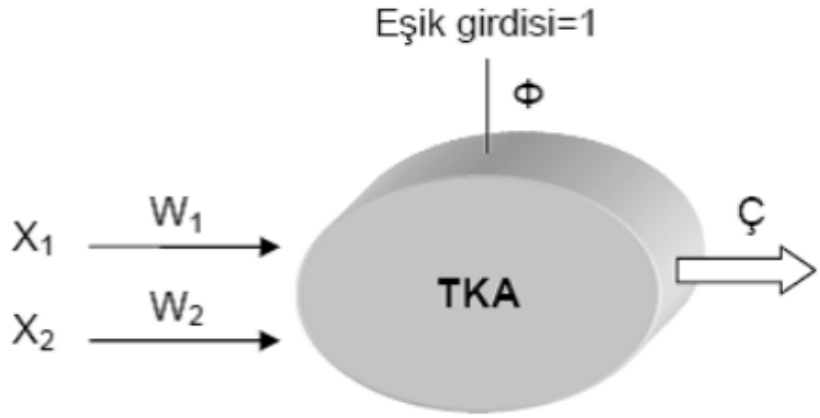
Veri Filtreleme: Bu amaçla eğitilen ağlar, birden fazla veri arasından uygun olan verileri belirleyerek görevlerini tamamlarlar.[47]

2.9.2. Yapay Sinir Ağı Modelleri

Yapay sinir ağı modelleri tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli YSA ve geri beslemeli YSA olmak üzere dört farklı grupta incelenir.

-Tek katmanlı algılayıcılar

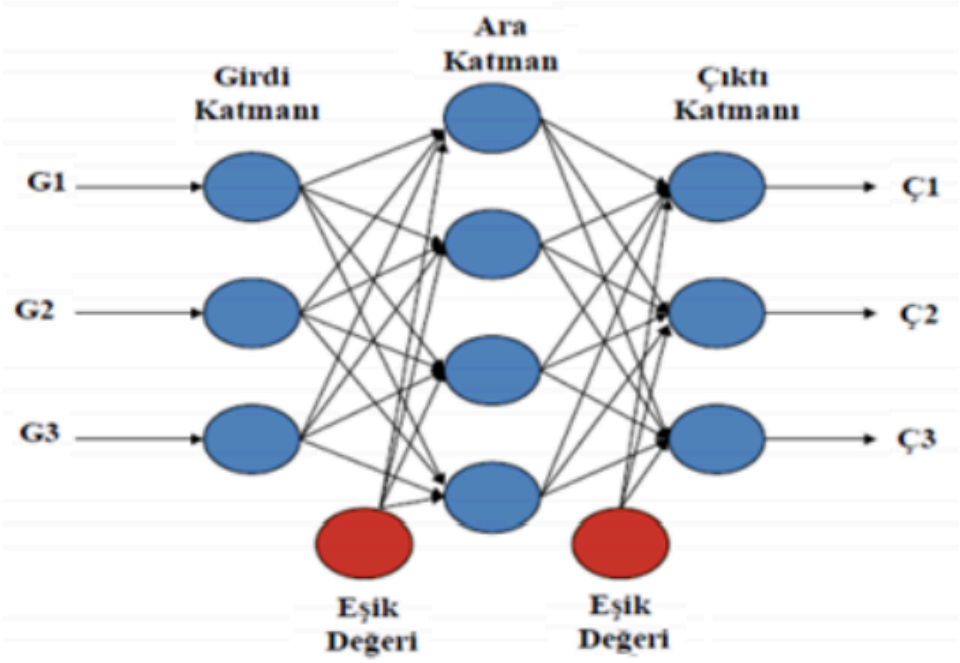
Tek katmanlı ağlar yalnızca girdi ve çıktıdan oluşmaktadır. Bu algılayıcılarda çıktı fonksiyonu doğrusaldır ve 1 veya -1 değerlerini almaktadır.[43]



Şekil 2.4 Tek katmanlı algılayıcı modeli[40]

- Çok katmanlı Algılayıcılar

Çok katmanlı algılayıcılar yapısal olarak doğrusal olmayan aktivasyon fonksiyonu olan birden fazla nöronun belli bir üstünlük içerisinde bağlandığı yapı olarak tanımlanmaktadır.[40]



Şekil 2.5 Çok katmanlı algılayıcı modeli[40]

- İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli ağlarda sinyal iletimi, bir katmandaki nöronlardan, bir sonraki katmandaki nöronlara doğru yapılır ve aynı katmandaki nöronlar arası bağlantı bulunmaz.[48]

- Geri beslemeli Yapay Sinir Ağları

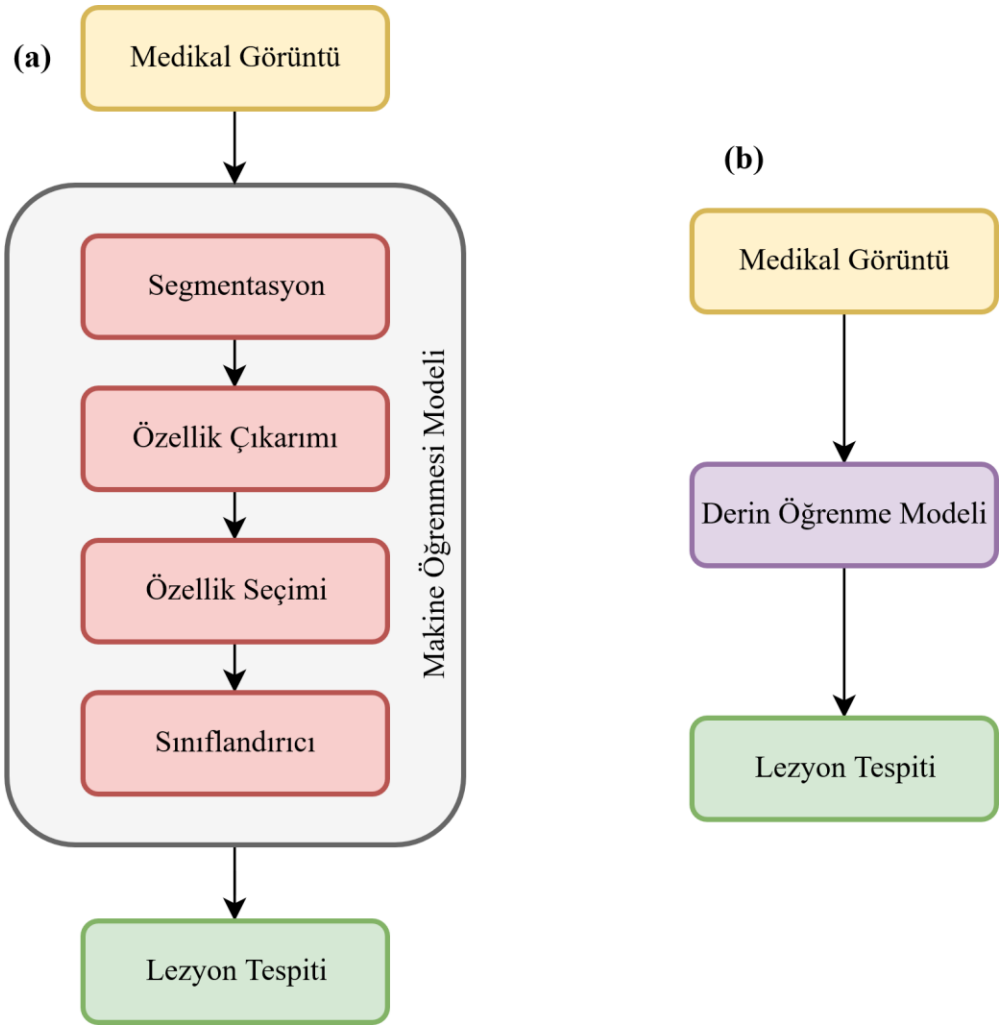
Geri beslemeli ağlarda ise, sinyal iletimi iki yönlü (ileri ve geri) olarak da mümkündür ve bir çıkış sinyali, giriş ve çıkış değerlerini dinamik bir şekilde kontrol edebilmektedir. YSA'nın istenilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması, yani eğitilmesi gerekir. YSA, istenen davranışı gösterecek biçimde problemden edindiği eğitim örneklerini kullanarak, problemi öğrenmelidir. Belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir.[48]

2.10. Derin öğrenme ve Derin Evrişimli Sinir Ağları

Derin öğrenme, makine öğreniminin bir bileşenidir. Girdi verilerini analiz etmek için derin bir sinir ağında farklı hesaplama katmanlarına sahip ağı kullanır. Derin öğrenmenin amacı, özellik algılamayı iyileştirmek için kalıpları otomatik olarak tanımlayan bir sinir ağı oluşturmaktır. Soyutlanmış filtre katmanından özellikler toplarlar ve öncelikle büyük ve karmaşık işlemek için kullanılırlar.[35]

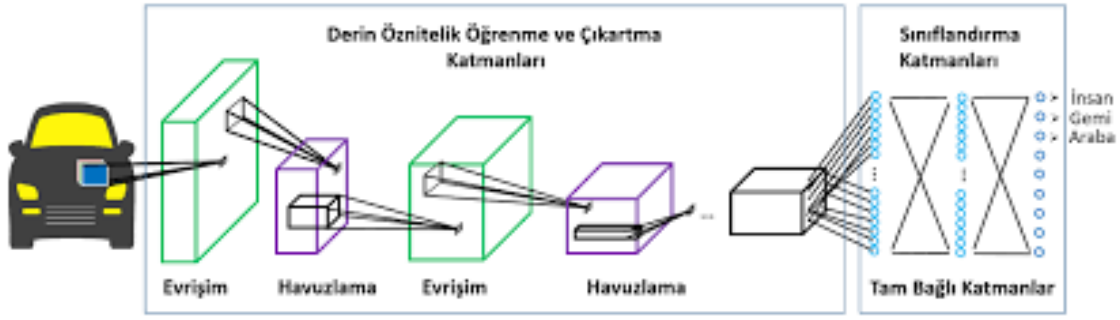
Derin öğrenme modelleri giriş bilgisi olarak bölümlere ayrılmış nesnelerden hesaplanan özellikler yerine doğrudan görüntülerdeki piksel değerlerini kullanır.

ML modellerinin aksine, yapılan eğitim sonucunda, sadece ham veriyi işleyerek çıkarım yapabilme özelliğine sahiptir. Genellikle belirsiz veya karmaşık nesneler için meydana gelen hatalı özellik hesaplaması ve segmentasyonun neden olduğu hataları önleyebilmektedir. (Şekil 2.6)[49]



Şekil 2.6 a) Makine öğrenmesi ve b) derin öğrenme.[49]

Derin öğrenme yapay zekanın en yeni alt kümesidir, temel olarak girdiler ve çıktılar arasındaki ANN, katman sayısı bakımından önceki ANN'lerden farklıdır. Bu katmanlar sayesinde girdilerden veri toplar.[41,50] Bu fazla sayıda katmandan oluşan ağ yapılarına derin DCNN adı verilmektedir (Şekil 2.7). Katmanlarından çeşitli birden fazla özelliği çıkarabilen bu yapılar, asıl olarak daha büyük ve karmaşık görüntüleri işlemek için kullanılmaktadır.[44] Çeşitli görevleri yapıcak olan bu katmanlar sağlık alanı ile ilgili görüntülerde; hastalık teşhis etme, sınıflandırma, nesne tanımlama gibi işlemleri gerçekleştirebilirler.[42]



Şekil 2.7 DCNN mimarisi[51]

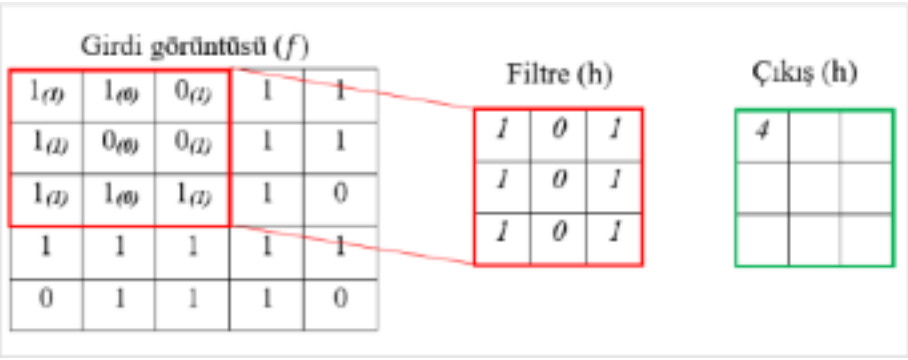
2.11. Evrişimli Sinir Ağı Katmanları

2.11.1. Giriş Katmanı

DCNN'ye ham olarak verilen giriş görüntüsünü belirtmektedir.[42]

2.11.2. Evrişim Katmanı

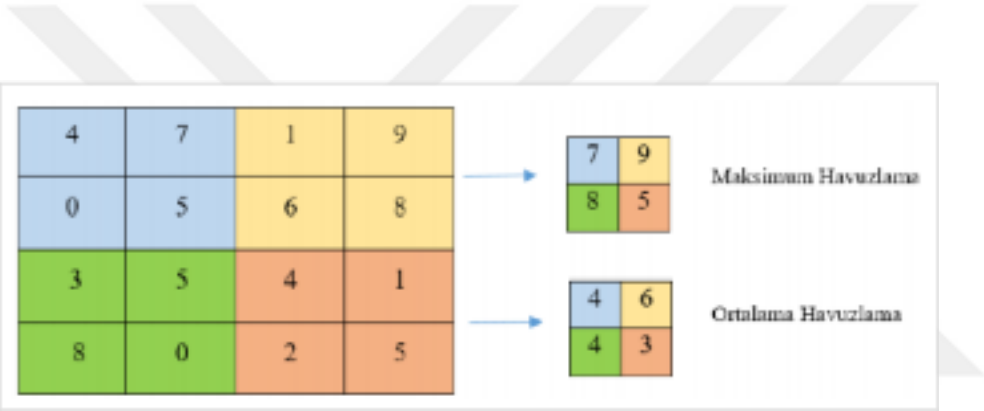
Bir evrişim katmanı, girdiyi ilgili özellikleri çıkararak yoğunlaştırır ve farklı özellik dedektörlerine yanıt olarak özellik haritaları üretir. İlk evrişim katmanında, kenarlar gibi basit özellikler nöronlar tarafından filtrelenir. Nöronlar, evrişim katmanlarında görüntünün daha büyük bir resmini elde etmek için bilgileri toplamayı öğrenirler, dolayısıyla yüksek dereceli bir tespit sağlar.[52]



Şekil 2.8 Evrişim işlemi[52]

2.11.3. Havuzlama Katmanı

Havuzlama veya alt örnekleme, genel havuz oluşturma, örtüşen havuz oluşturma vb. gibi çeşitli işlem türlerini içerir. Genellikle birkaç evrişim katmanı arasında aracılık eder. Havuzlama, CNN'lere birçok fayda sağlar. Özellikle, havuzlama, yerel verileri bir havuzlama penceresiyle yoğunlaştırarak ve böylece veri boyutluluğunu azaltarak fazla tek bird değer olarak ifade etmeyi amaçlar. Veri boyutunun azaltılması da hesaplamaların azaltılmasına yardımcı olur.[52]



Şekil 2.9 Havuzlama işlemi[52]

2.11.4. Tam Bağlı Katman

Genellikle havuzlama katmanı ardından gelen bu katman, kendinden önce gelen bütün katmanın tüm alanlarına bağlıdır bu sebeple tam bağlantılı katman denilmektedir.[53]

2.11.5. Sınıflandırma Katmanı

Bu katman tam bağlantılı katmandan sonra gelmektedir. Derin öğrenme mimarilerinin bu katmanında sınıflandırma işlemi yapılmaktadır. Bu katmandaki çıkış değeri, sınıflandırması yapılacak olan nesne sayısına eşittir.[53]

2.12. Evrişimsel Sinir Ağlarının Eğitilmesi

İlk olarak evrişimsel sinir ağı modeli oluşturulur. Bu modelde konvolüsyon katman sayısı, havuzlama katman sayısı, tam bağlantılı katman sayısı ve sınıflandırma katmanı belirlenir. İkinci olarak model oluşturulur sonrasında başlangıç değişkenleri tanımlanır. Bu değişkenleri genel olarak filtre boyutları, filtre sayısı ve adım kayma miktarı olarak belirtebiliriz. Üçüncü olarak oluşturulan modele eğitim setinden bir görüntü verilir. Bu görüntüden sonuç elde edebilmek için ağdaki katmanlardan geçirilir. Bu segmente ileri besleme adı verilir. Bu aşamada belirtilen her katmanda her bir filtrenin ağırlıkları ile görüntüdeki piksel değerleri çarpılarak bir sonraki katmana aktarılır. Hedef sonuçlar ve üretmiş olduğu sonuçların farkı alınarak hata değeri elde edilir ve bu değer ağdaki bütün ağırlıklara dağıtılır.[53]

2.13. Aktivasyon Fonksiyonu

Sinir ağlarında giriş değerleri ağırlık değerleri ile çarpılır sonra bir aktivasyon fonksiyonundan geçirilerek bir çıktı elde edilir. Aktivasyon fonksiyonları sinir ağlarında doğrusal olan ifadeleri doğrusal olmayan ifadelere dönüştürür. Aktivasyon fonksiyonları ağın öğrenmesini ve optimizasyon sürecini de etkilerler.[54]

2.14. Transfer Öğrenme

Derin evrişimli sinir ağları eğitiminde en büyük problem veri setinin az olduğu durumlardır. Transfer öğrenme bu probleme yönelik olarak önceden eğitilmiş bir CNN modelinin sınıflarını probleme göre değişiklik yaparak hedef veri kümesi üzerinde ince

ayar yapan parametrelerin aktarımının öğrenilmesinin sağlar. Bu DCNN modellerine AlexNet, VGGNet, GoogleNet ve ResNet mimarileri örnek verilebilir.[55]

2.15. Diş Hekimliğinde Yapay Zeka Ve Kullanım Alanları

Yapay zeka, özellikle diş hekimliğinde, konforlu hasta bakımına ilave olarak uygulanan tedavilerde en iyi sonuçların alınmasında büyük önem arz eden tanı süresini daha doğru ve verimli hale getirmek için kullanılmıştır.

Diş hekimlerinin olabilecek en iyi tedavi seçeneğini belirlemek ve karar vermek için edindikleri tüm bilgileri kullanmaları gerekmektedir. Ayrıca, klinik tedavide doğru karar verme yetkinliklerine ihtiyaç duyduklarında tanıyı tahmin etmeleri gerekir. Ancak bazı durumlarda diş hekimleri de kısa bir zaman içinde doğru klinik tedavi kararı vermek için yeterli bilgiye sahip olmamaktadır. AI uygulamaları, daha etkili kararlar alabilmeleri ve daha iyi tedavi süreci gösterebilmeleri için onlara rehberlik edebilmektedir.[35]

2.15.1. Ortodonti Alanında Yapay Zeka

Yapay zeka ortodonti alanında umut vaat etmektedir. Ortodontide yapay zekayı tanı-tedavi protokollerinde, landmark tespitinde, çekimli-çekimsiz tedavi kararında, iskeletsel sınıflandırmada, büyüme-gelişim döneminin tespit edilmesinde ve ortognatik cerrahi gibi çeşitli birçok analiz için kullanılabilmektedir.

Yu ve ark.[56] lateral sefalogramlarla 1 adımlı, uçtan uca bir tanı sistemine evrişimli bir sinir ağını (CNN) dahil ederek doğru ve sağlam bir iskeletsel tanı sistemi sağlamayı amaçlamışlardır. Önerilen sistemin dikey ve sagittal iskelet teşhisi için %90 duyarlılık, özgüllük ve doğruluk sergilediğini bildirmişlerdir.

Kök ve ark.[57], sefalometrik radyografide tanımlanan servikal vertebra evrelerini yapay zeka modeli ile inceleyerek büyüme ve gelişim dönemi tespiti yapmışlardır. Yapay zeka algoritmalarının, büyüme gelişiminin belirlenmesi gereken tüm bilimlerde teşhis amaçlı kullanılabileceğini böylece daha doğru ve tarafsız kararlar alınabileceğini bildirmişlerdir.

Xie ve ark.[58] AI modelini, diş çekiminin maloklüzyon için uygun bir tedavi olup olmadığını araştırmak için kullandı. maloklüzyon hastalarının çekime ihtiyacı olup olmadığını %80 doğrulukla doğru bir şekilde tespit ettiğini bulmuşlardır.

AI ile ortognatik cerrahi gerekliliği ve planlanması aşamasında da başarılı sonuçlar elde edilmiştir.[59]

-Sefalometrik Analiz ve Landmark Tespitinde Yapay Zeka

Cohen ve ark.[60] 1984 yılında otomatik sefalogram işaretleme için ilk girişimi yaptı. Lateral sefalometrik radyografilerde anatomik yapıları otomatik olarak algılayabilen programlar geliştirilmiştir. Anatomik noktaların otomatik olarak tespitine dair ilk çalışma, 1986 yılında Levy-Mandel ve ark. tarafından yapılmıştır.[61] Tıbbi görüntüleme için yapay zeka teknolojilerinin hızlı gelişimi, son zamanlarda radyograflarda anatomik yer işaretlerinin otomatik olarak tanımlanmasını sağlamıştır. Yapılan bir çalışmada yapay sinir ağına dayalı otomatik sefalometrik analizlerin, klinik olarak kabul edilebilir ve teşhis performansı sunabileceğini bildirilmiştir.[62]Yapay zekâ algoritmasına sahip programlar, makine öğrenmesini kullanarak, görüntüler üzerinde tanısal ve analitik sonuçlar içeren sefalometrik analizler yapabilmektedir. Derin öğrenme algoritmasi ile ilgili çalışmalar, yapay zekanın sefalometrik radyografiler üzerinde anatomik noktaları doğru olarak tespit ettiğini göstermiştir.[63]

3. MATERYAL VE METOT

3.1. Hasta Seçimi

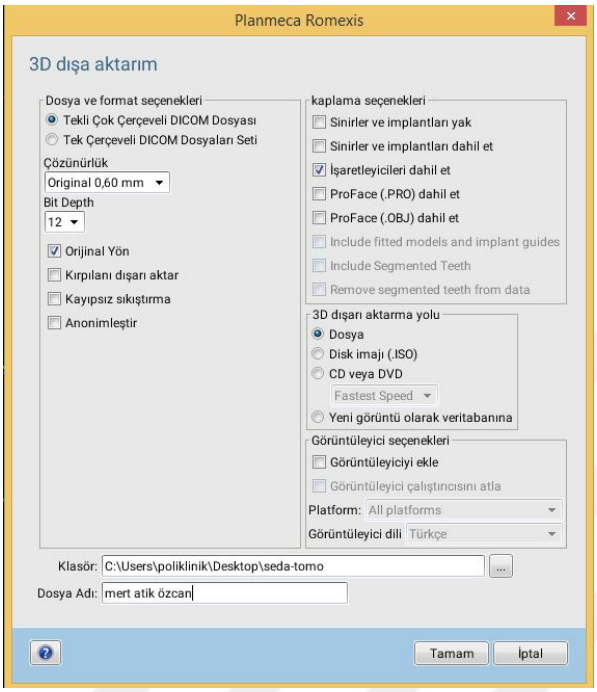
Bu çalışmada ortodontik tedavi amacıyla Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalına başvuran hastaların ultra düşük doz KIBT verilerinden elde edilen sefalometrik radyografik görüntüler kullanıldı. Veri seti Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı radyografi arşivinden Ocak 2013-Eylül 2021 tarihleri arasında alınmış karma veya daimi dişlenme dönemindeki 1102 hastanın KIBT görüntü kayıtlarından oluşmaktadır. Radyograflarda pozisyon hatası, ortodontik aparey, implant vb. kaynaklı metal artefaktlar, kraniyofasiyal sendromu, dudak damak yarığı olan hastalar radyografik görüntüleri, travma ve maksillofasiyal cerrahi çalışma verileri hariç tutuldu. Çalışma protokolü Eskişehir Osmangazi Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Komitesi tarafından onaylandı. (onay numarası: 30 Ekim 2021/26) çalışma protokolünü onayladı ve tüm işlemler Helsinki Bildirgesi ilkelerine uygun olarak yapıldı.

3.2. Sefalometrik Radyograf Veri Setinin Oluşturulması

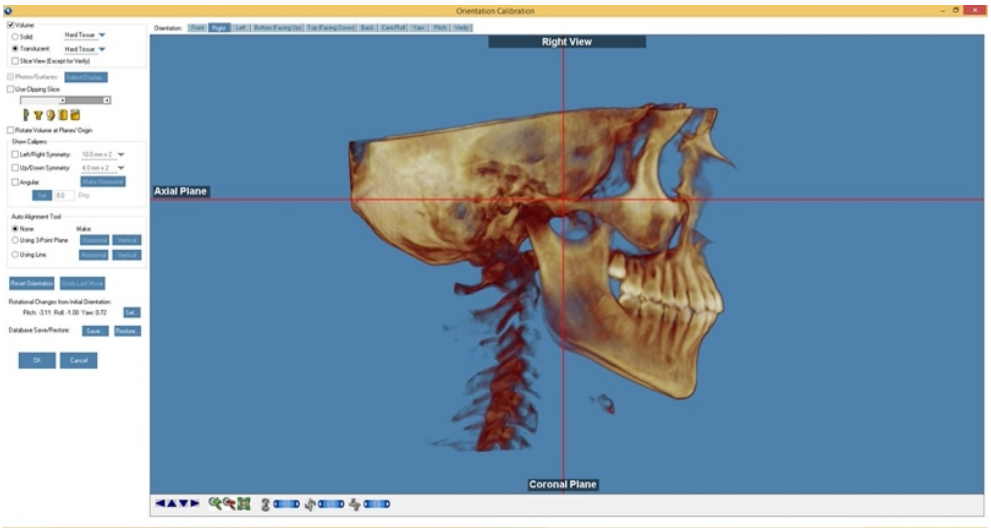
Arşivdeki tüm görüntüler aynı KIBT cihazı (Promax 3D Mid; Planmeca, Helsinki, Finlandiya) kullanılarak elde edildi. Görüntüleme parametreleri: tüp voltajı 94 kVp, X-ışını tüp akımı 14 mA (miliamper), 360° dönme, tarama süresi 27 sn ve voksel boyutu 0.600 mm'dir. KIBT görüntüleri Digital Imaging and Communication in Medicine (DICOM) dosyaları şeklinde kaydedildi. Çalışmada 1102 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 olucak şekilde ayarlanıp daha sonrasında sefalometrik radyograflar oluşturuldu.

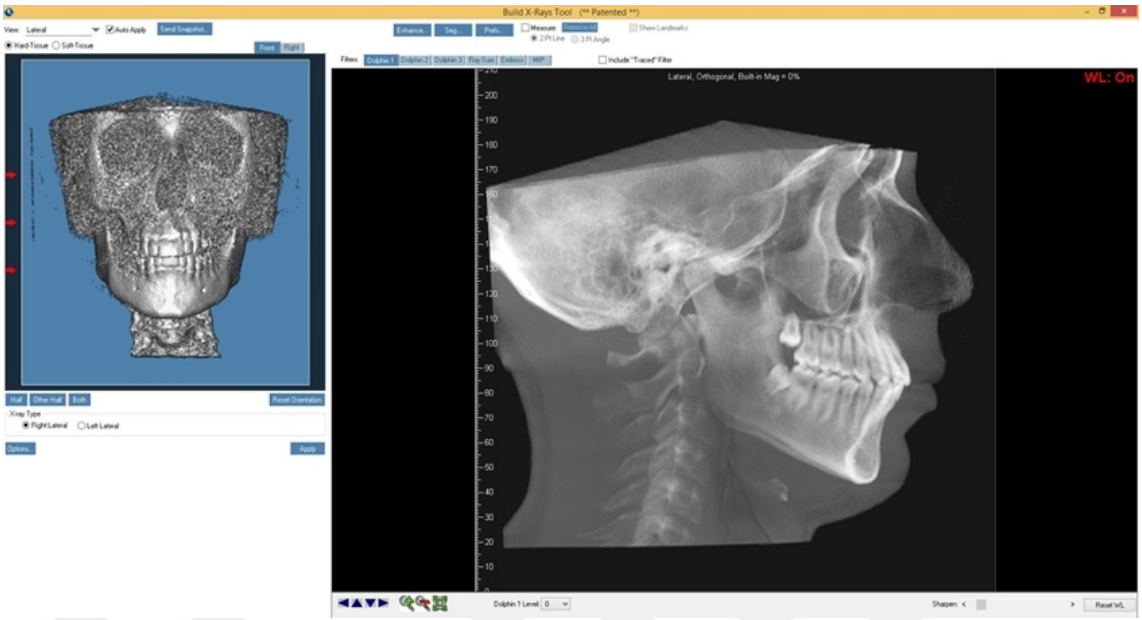
Elde edilen sefalometrik radyograflar CranioCatch etiketleme yazılımına (Eskişehir, Türkiye) yüklenerek proje oluşturuldu.



Şekil 3.1 KIBT görüntüsünün dışa aktarımı



Şekil 3.2 Baş pozisyonunun ayarlanması



Şekil 3.2 Dolphin İmaging programında sefalometrik radyograf oluşturulması

3.3. Veri etiketleme

Etiketleme, bir görüntüdeki noktanın tanımlanması ve tanımlanan noktanın hangi refrans noktası olduğunun belirlendiği işlemdir. Bin yüz hastanın KIBT görüntülerinden elde edilen sefalometrik radyograflar Cranio Catch 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 AI 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.

3.4. Sefalometrik Radyograflar Üzerinde İşaretlenen Referans Noktaları

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 yumuşak doku noktaları ve iskeletsel,dental noktalar işaretlendi. Radyografi görüntüleri %150 oranında büyütülerek noktalama işlemleri gerçekleştirilmiştir. Kullanılan noktalar aşağıdaki gibi isimlendirmekte ve tanımlamaktadır.

3.4.1. Yumuşak Doku İşaret Noktaları

Glabella (G'): Alnın midsagittal eksende en anteriorda olduğu nokta.

Yumuşak doku Nasion (N'): Burun kemiğinin başlangıç kısmındaki yumuşak doku sınırının en derin noktası.

Yumuşak doku Nasal dorsum noktası: Burun üzerindeki profil uzunluğu boyunca karşılaşılan ilk kontur. (Nasion ve burun ucu arasındaki orta nokta)

Pronasale (Pn): Burun ucunun en anteriorda bulunan noktası.

Columella (Cm): Burnun inferiorunda bulunan kıvrım üzerindeki en anterior nokta.

Subnasale (Sn): Burnun alt sınırının dudağın dış kısmı ile birleştiği nokta.

Yumuşak doku A noktası (A'): Üst dudak içbükeyliğinin en derin noktası.

Labrale superior (Ls): Üst dudağın en anterior noktası.

Stomion superius (Ss): Üst dudağın en inferior noktası.

Stomion inferius (Si): Alt dudağın en superior noktası.

Labrale inferior (Li): Alt dudağın en anterior noktası.

Yumuşak doku B noktası (B'): Li ve Pg' noktaları ortasındaki alt dudağın konkavitesinin en derin noktası.

Yumuşak doku Pogonion noktası (Pg'): Mandibula ucu yumuşak dokusunun en anterior noktası.

Yumuşak doku Gnathion noktası (Gn'): Alt çene ucu yumuşak dokusunun en ön ve en alt noktası.

Yumuşak doku Menton (Me'): Yumuşak doku mandibula ucunun en inferior noktasının boyun düzlemi ile birleştiği nokta.

3.4.2. İskeletsel İşaret Noktaları

Sella (S): Sella turcica'nın geometrik merkezi.

Nasion (N): Frontonasal suturun en anterior ve o alandaki en derin noktası.

Basion (Ba): Foramen occipitale magnum'un anterior kenarının en anterior noktası.

Gnathion (Gn): Mandibulanın ön ve alt kenar görüntü konturunun Pogonion ve Menton noktaları arasında kalan kısmının ortası.

Orbitale (Or): Göz çukuru alt sınırının en derin noktası.

Pterygoid nokta (Pt): Lateral sefalometrik görüntülerde foramen rotundumun alt sınırı ile pterygoid maksiller fossanın kesişme noktası.

Porion (Po): Dış kulak yolunun en superior noktası.

Ramus (Ra): Ramusun dış sınırındaki vertikal en dışbükey nokta.

Hinge Axis(HA): Mandibulanın sagital düzlemde etrafında dönebildiği mandibular kondil üzerindeki nokta.

Gonion (Go): Mandibulada corpusun alt kenarı ile mandibuler ramusun arka kenarının birleşim noktası.

A noktası: Anterior nasal çıkıntı altındaki maksilla ön alveol kemik girintisinin en derin noktası.

B noktası: Pogonion noktasının üst kısmındaki mandibula ön alveolar kemik girintisinin en derin noktası.

Menton (Me): Alt kesici dişlerin köklerinin iç tarafını örten alveol kemiği görüntüsünün en arka çizgisi aşağıya doğru izlendiğinde bu çizginin alt çene alt kenarıyla birleştiği nokta.

Articulare (Ar): Mandibulanın kondiler çıkıntısının (processus articularis ossis mandibularis) arka kenarı ile kafa kaidesi dış sınırının kesişme noktası.

Anterior Nasal Spina (ANS): Orta oksal düzlemde maksillanın en ön noktası.

Posterior Nasal Spina (PNS): Palatinal kemiğin posterior en uç noktasıdır.

Pogonion (Pg): Mandibular symphisis'in en ön noktasıdır.

3.4.3. Dental İşaret Noktaları

Mx1c: Üst 1. santral dişin kronunun ucu.

Mx1r: Üst 1.santral dişin kökünün ucu.

Md1c: Alt 1 numaralı keser dişin kronunun ucu.

Md1r: Alt 1 numaralı keser dişin kökünün ucu.

U6o: Üst birinci büyük azı dişinin mezio-bukkal tüberkül tepesi.

L6o: Alt birinci büyük azı dişinin mezio-bukkal tüberkül tepesi.

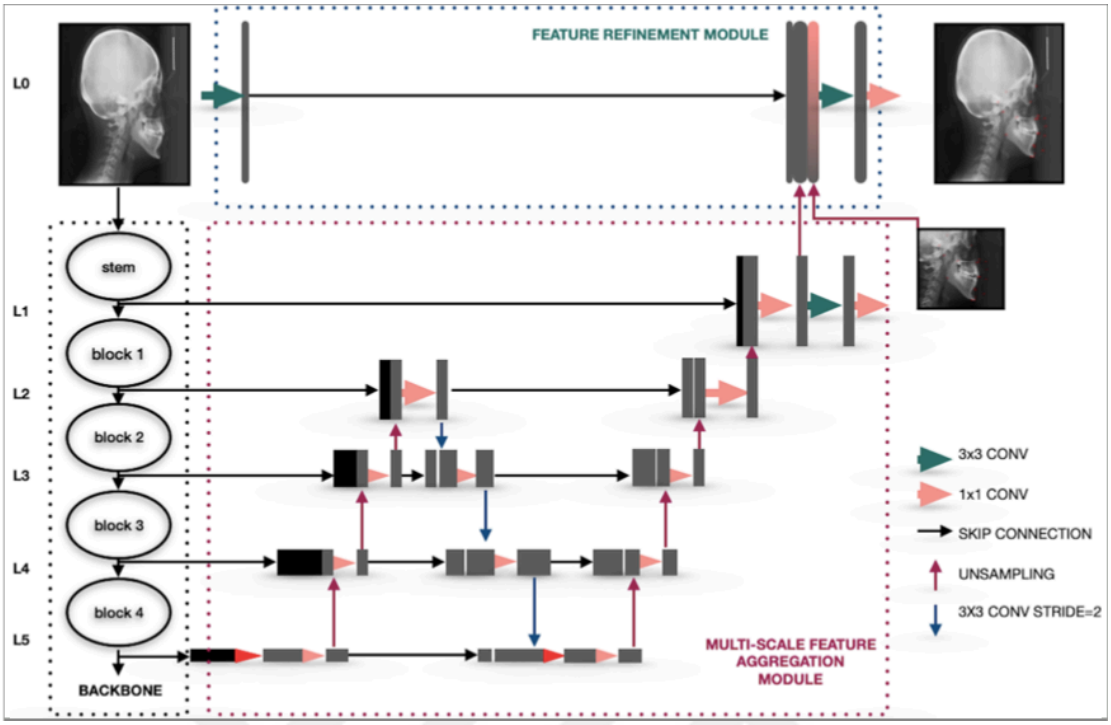
Mx6m: Üst birinci büyük azı dişinin mezial kontakt noktası.

Mx6d: Üst birinci büyük azı dişinin distal kontakt noktası.

Md6m: Alt birinci büyük azı dişinin mezial kontakt noktası.

Md6d: Alt birinci büyük azı dişinin distal kontakt noktası.

3.5. Derin Öğrenme Mimarisi



Şekil 3.3 Özellik toplama ve iyileştirme ağının (FARNet) mimarisi. FARNet, bir omurga ağı, çok ölçekli bir özellik toplama (MSFA) modülü ve bir özellik iyileştirme (FR) modülü içerir.

Yueyuan ve ark.[64] tarafından önerilen özellik toplama ve iyileştirme ağı (FARNet), CNN 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[65], ResNet[66] veya DenseNet[67] 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 3.4) 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.[64]

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 gerçekleştiririz. Deneysel doğrulama yoluyla, özellik iyileştirme modülümüz tahminin doğruluğunu etkin bir şekilde artırabilir.[68]

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 16 yumuşak doku noktası, 18 iskeletsel doku noktası ve 8 dişsel nokta etiketli 1102 sefalometrik karışık boyutlu görüntü elde edildi.

3.7 Eğitim Aşaması

Görüntüler ve etiketler 1935 × 2400 olarak yeniden boyutlandırıldı. Her nokta için bir satır belirlenmiştir. Etiketler belirtilen sırada 42 nokta olarak txt formatında kaydedildi. Veri setleri eğitim, test ve doğrulama olarak 3 bölüme ayrıldı:

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

Eğitim veri seti: Modelin eğitimini sağlamak için kullanılan veri setini oluşturmaktadır.[69]

Doğrulama veri seti: Modelin eğitiminden bağımsız olan ve bu süreçte modelin görmemesi gereken örnekleri oluşturmaktadır.[69]

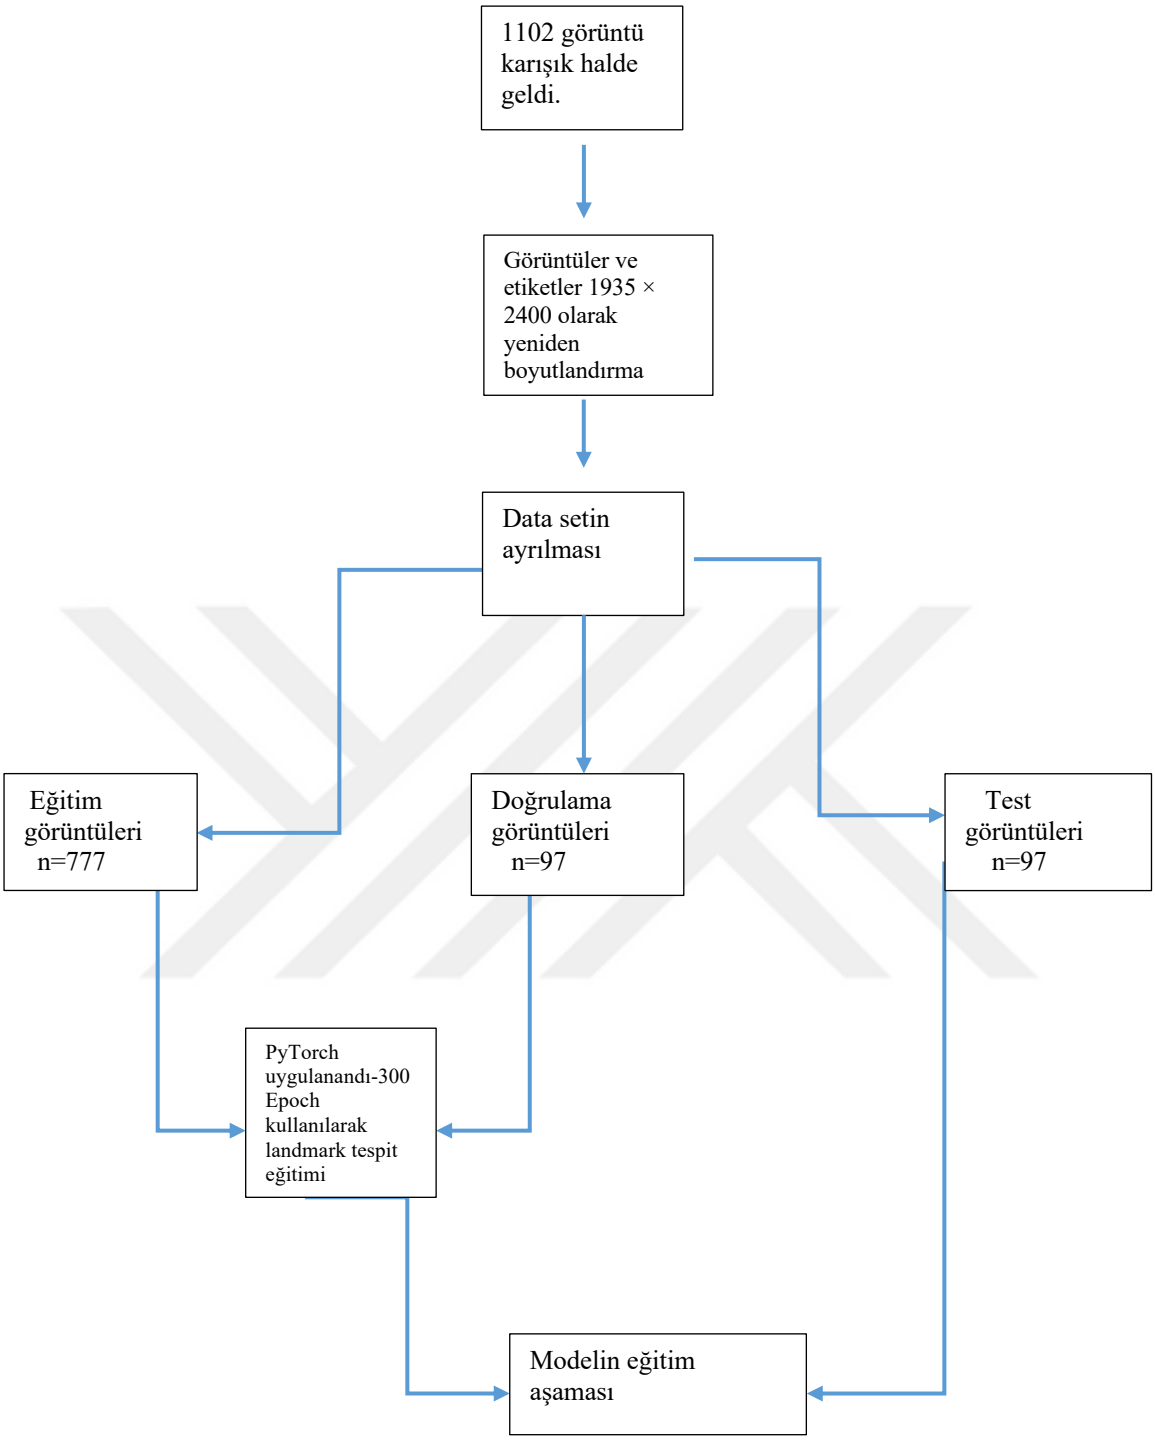
Test veri seti: Eğitim ve doğrulama verileri kullanılarak eğitilen modelin denemeainin yapıldığı veri setini oluşturmaktadır.

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

Tablo 4.1 Sefalometrik nokta tespitinin SDR ve MRE değerleri

EĞİTİM:	777 görüntü
DOĞRULAMA:	97 görüntü
TEST:	97 görüntü

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



Şekil 3.4 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.[68]

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

MRE ve SD, aşağıdaki formül kullanılarak hesaplandı[68]:

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

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

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.[68]

4. BULGULAR

Çalışmamızda sefalometrik landmark tespiti için kullanılan derin öğrenme modelinin, KIBT görüntülerinden elde edilen lateral sefalometrik radyograflar üzerinde ortodontik analizlerde kullanılan dişsel, iskeletsel noktaların ve yumuşak doku noktalarının tespitinin başarısı araştırıldı.Sunulan AI sistemi (CranioCatch, Eskişehir, Türkiye) bir lateral sefalometrik radyografide 44 anatomik noktayı saptayabilir.

En yüksek SDR puanı 2 mm, 2.5 mm, 3 mm ve 4 mm ile Columella(Cm), Mandibular 1.moların mesiali(Md6m) ve Yumuşak doku B(B') noktasından sırasıyla 100, 100, 100 ve 100 olarak elde edildi. Cm'nin MRE ± SD değeri 0.78 ± 0.41, Md6m'nin MRE±SD değeri 0,74±0,38 ve B'nin MRE ± SD değeri 0,72±0.38 olarak bulundu.

Gnathion(Gn) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 98.9, 100, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.6±0.4 olarak bulundu.

Alt 1.moların mezio-bukkal tüberkül tepe noktası (L6o) için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 98.9, 100, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.8±0,4 olarak bulundu.

Labrale superior(Ls) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 98.9, 100, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.52±0.25 olarak bulundu.

Orbitale(Or) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 98.9, 98.9, 98,9 ve 100 olarak elde edildi. MRE±SD değeri 0.59±0.43 olarak bulundu.

Pogonion(Pg) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 98.9, 98.9, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.61±0.37 olarak bulundu.

Stomion superius(Ss) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 98.9, 100, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.80±0.38 olarak bulundu.

Subnasale(Sn) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 98.9, 98.9, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.65±0.46 olarak bulundu.

Menton(Me) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 97.8, 98.9, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.86±0.49 olarak bulundu.

Nasion(N) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 97.8, 98.9, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.70±0.50 olarak bulundu.

Yumuşak doku A noktası(A') noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 97.8, 98.9, 98.9 ve 98.9 olarak elde edildi. MRE±SD değeri 0.77±0.55 olarak bulundu.

Stomion inferius(Si) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 97.8, 100, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.65±0.41 olarak bulundu.

A noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 93.6, 97.8, 97.8 ve 100 olarak elde edildi. MRE±SD değeri 0.87±0.59 olarak bulundu.

Articulare(Ar) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 95.7, 97.8, 98.9 ve 100 olarak elde edildi. MRE±SD değeri 0.67±0.51 olarak bulundu.

B noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 96.8, 98.9, 98.9 ve 100 olarak elde edildi. MRE±SD değeri 0.82±0.54 olarak bulundu.

Basion(Ba) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 91.5, 95,7 96,8 ve 100 olarak elde edildi. MRE±SD değeri 1.03±0.71 olarak bulundu.

Pronasale(Pn) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 95.7, 98.9, 100 ve 100 olarak elde edildi. MRE±SD değeri 0.80±0.48 olarak bulundu.

En düşük SDR puanı olan 2 mm, 2,5 mm, 3 mm ve 4 mm Pterygoid(Pt) noktasından sırasıyla 65,2, 77.8, 85.2 ve 94.7 olarak elde edildi. Pt'nun MRE ± SD değeri 1.731±1.17 olarak bulundu.

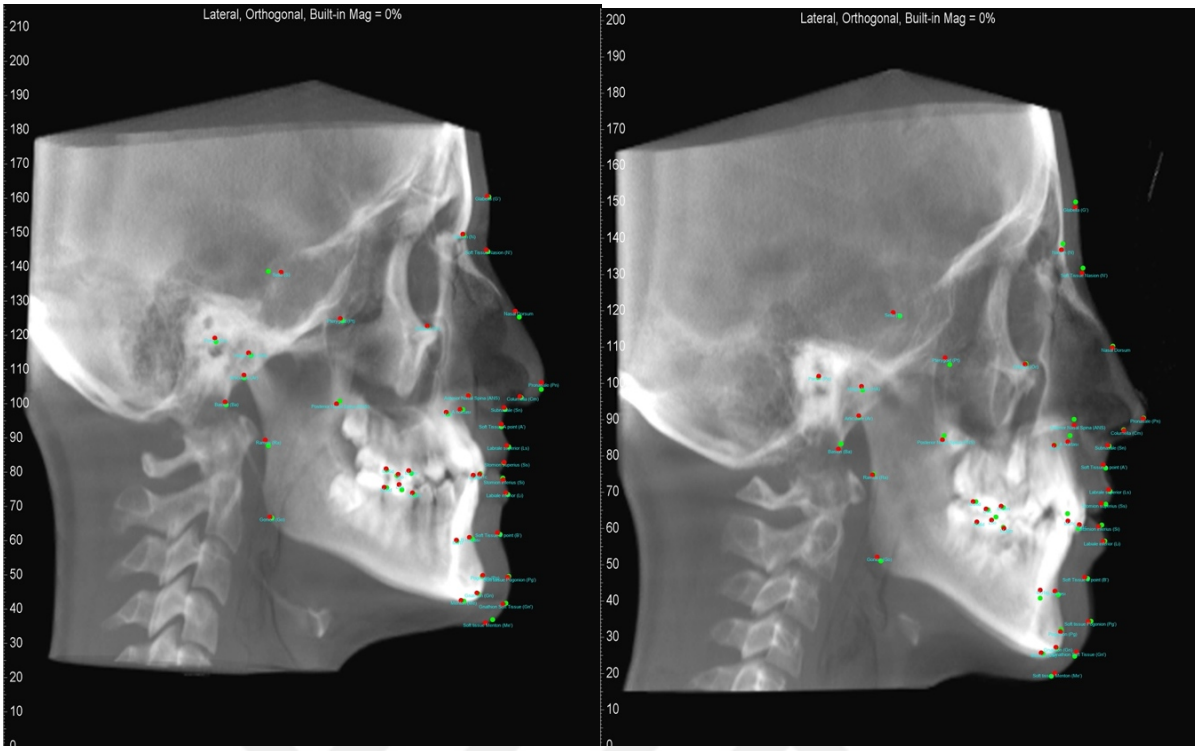
Glabella(G') noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 71.5, 86.3, 88.4 ve 93.6 olarak elde edildi. MRE±SD değeri 1.6±1.45 olarak bulundu.

Posterior nasal spina(PNS) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 77.8, 88.4, 93.6 ve 9.8 olarak elde edildi. MRE±SD değeri 1.34±0.95 olarak bulundu.

Ramus(Ra) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 72.6, 85.2, 86.3 ve 94.7 olarak elde edildi. MRE±SD değeri 1.51±1.12 olarak bulundu.

Sella(S) noktası için SDR puanı 2 mm, 2,5 mm, 3 mm ve 4 mm için sırasıyla 83.1, 87.3, 87.3 ve 94.7 olarak elde edildi. MRE±SD değeri 1.48±2.14 olarak bulundu.

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



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

Tablo 4.2 Sefalometrik nokta tespitinin SDR ve MRE değerleri

Point	**<=2.0**	**<=2.5**	**<=3.0**	**<=4.0**	**mean radial error**	**sd**
A noktası	0,936842105	0,978947368	0,978947368	1	0,873866475	0,595410615
Anterior Nasal Spina (ANS)	0,905263158	0,968421053	0,978947368	0,989473684	0,961623192	0,789309026
'Articulare (Ar)	0,957894737	0,978947368	0,989473684	1	0,671529977	0,519461535
B noktası	0,968421053	0,989473684	0,989473684	1	0,823774188	0,544288176
Basion (Ba)	0,915789474	0,957894737	0,968421053	1	1,033063682	0,716430839
Columella (Cm)	1	1	1	1	0,788568848	0,416841912
Glabella (G')	0,715789474	0,863157895	0,884210526	0,936842105	1,600171814	1,458666841
Gnathion (Gn)	0,989473684	1	1	1	0,600797592	0,401955856
Gnathion Soft Tissue (Gn')	0,873684211	0,884210526	0,957894737	0,989473684	1,106849132	0,816348461

Gonion (Go)	0,884210526	0,92631579	0,957894737	0,989473684	1,025893903	0,887653875
Hinge Axis (HA)	0,936842105	0,968421053	0,968421053	0,989473684	1,068504668	0,662474542
L6o	0,989473684	1	1	1	0,800512312	0,401037381
Labiale inferior (Li)	0,968421053	0,978947368	0,989473684	1	0,62485505	0,554407219
Labrale superior (Ls)	0,989473684	1	1	1	0,520868987	0,257517781
Md1c	0,978947368	0,989473684	0,989473684	0,989473684	0,701114473	0,594584532
Md1r	0,978947368	0,989473684	1	1	0,715438979	0,467562287
Md6d	0,978947368	0,989473684	1	1	0,811677605	0,468695352
Md6m	1	1	1	1	0,742460591	0,381813051
Menton (Me)	0,978947368	0,989473684	1	1	0,8602857	0,494369074
Mx1c	0,978947368	0,978947368	0,989473684	0,989473684	0,628818462	0,602110862
Mx1r	0,947368421	0,968421053	0,978947368	0,978947368	0,818303205	0,832455296
Mx6d	0,957894737	0,978947368	0,978947368	0,978947368	0,910316629	1,116444248
Mx6m	0,978947368	0,978947368	0,978947368	0,978947368	0,862478594	0,975911852
Nasal Dorsum	0,884210526	0,915789474	0,947368421	0,989473684	1,251311269	0,800466277
Nasion (N)	0,978947368	0,989473684	1	1	0,705487048	0,503668746
Orbitale (Or)	0,989473684	0,989473684	0,989473684	1	0,595282137	0,438605721
Pogonion (Pg)	0,989473684	0,989473684	1	1	0,613521521	0,377075751
Porion (Po)	0,936842105	0,968421053	0,978947368	0,989473684	0,892671987	0,985860475
Posterior Nasal Spina (PNS)	0,778947368	0,884210526	0,936842105	0,978947368	1,343831494	0,950700265
Pronasale (Pn)	0,957894737	0,989473684	1	1	0,802215427	0,484691422
Pterygoid (Pt)	0,652631579	0,778947368	0,852631579	0,947368421	1,731939826	1,17919467
Ramus (Ra)	0,72631579	0,852631579	0,863157895	0,947368421	1,512168085	1,129898947
Sella (S)	0,831578947	0,873684211	0,873684211	0,947368421	1,489703019	2,141254725
Soft Tissue A point (A')	0,978947368	0,989473684	0,989473684	0,989473684	0,778694269	0,550464245
Soft Tissue B point (B')	1	1	1	1	0,720184456	0,381699368
Soft Tissue Nasion (N')	0,863157895	0,957894737	0,989473684	1	1,088285008	0,736122117
Soft tissue Menton (Me')	0,821052632	0,894736842	0,957894737	0,989473684	1,33584181	0,832013009

Soft tissue Pogonion (Pg')	0,905263158	0,947368421	0,978947368	1	0,867347374	0,743267045
Stomion inferius (Si)	0,978947368	1	1	1	0,658223869	0,415595507
Stomion superius (Ss)	0,989473684	1	1	1	0,800721753	0,383362502
Subnasale (Sn)	0,989473684	0,989473684	0,989473684	1	0,651571842	0,462461553
U6o	0,978947368	0,978947368	0,978947368	0,978947368	0,852615467	0,885050646

5. TARTIŞMA

Kafa tabanı ile maksilla veya mandibula arasındaki iskeletsel ilişkiyi, maksilla ve mandibula arasındaki ilişkiyi ve dentoalveolar ilişkiyi nicel olarak değerlendirmek için ortodontistler tarafından sefalometrik radyografiler alınır.[70]

İskelet sınıflandırma, lateral sefalogramlarda çenelerin dikey ve ön-arka pozisyonları ile değerlendirilen ortodontik tanı ve tedavi planlamasının önemli bir parçasıdır. Lateral sefalogramın değerlendirilmesi, klinisyenlerin kondiler büyümenin yönü veya dentoalveolar gelişim gibi çeşitli büyüme modellerini tahmin etmelerine ve vakaları teşhis etmesine ve tedavi planlamasına yardımcı olur. Bu nedenle, uygun sefalometrik noktaları tanımlama ve analizine dayalı doğru teşhis, başarılı bir tedavi için gerekli olmuştur.[71, 72]

Sefalometrik analiz için otomatik landmark noktası tespiti on yıllardır odak noktası olurken, DL'nin muhtemelen daha az gelişmiş sistemleri aştığı gösterilmiştir. Ayrıca, farklı şirketlerden (örneğin, CellmatIQ, Hamburg, Almanya; ORCA AI, Herzliya, İsrail; WebCeph, Gyeonggi-do, Kore) DL tabanlı sefalometrik yazılım uygulamaları artık dünya çapında ortodontistlerin kullanımına sunulmuştur.[73]

2-D ve 3-D sefalometrik görüntülerde dönüm noktası tespiti için DL'yi içeren çalışmaların sayısı hızla artarken, ortaya çıkan kanıtların 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. Bizim çalışmamızdaki amacımız 3 boyutlu görüntülerden elde ettiğimiz 2 boyutlu sefalogramlardaki DL'nin doğruluğunu araştırarak belirsizliğin giderilmesine yardımcı olmaktır.

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 landmark noktası saptama zorlukları düzenlenmiş ve 19 sefalometrik simgeden oluşan halka açık veri seti oluşturulmuş. Bu veri seti kullanılarak, birçok çalışmada sefalometrik dönüm noktası tespiti için Bayes evrişimli sinir ağları ve kademeli CNN'ler gibi farklı AI yöntemleri uygulanmıştır.

Zeng ve ark.[74] ISBI 2015 Grand Challenge'dan aldıkları 400 adet sefalometrik radyograf veri setinde 19 noktanın otomatik sefalometrik işaret noktası tespiti için kademeli CNN'lere dayalı bir yol önermişlerdir. Noktaların tespiti için Align-net, proposal-net ve refine-net yapay zeka mimarilerini kullanmışlar.

Lee ve ark.[75] da veri setini, ISBI 2015 yarışması tarafından sağlanan 400 denekten alınan sefalometrik radyograflardan oluşturdular ve Bayesian CNN'leri kullanarak sefolametrik noktaları tespitini değerlendirmişler. Bizim çalışmamızda Eskişehir Osmangazi üniversitesine başvuran 1102 hastadan alınan radyografiler veri setimizi oluşturduk ve sefalamotrik nokta tespiti için Far-net derin öğrenme mimarisi kullandık.

Yueyuan ve ark.[64] Bizim çalışmamızda kullandığımız FAR-net mimarisini U-net ve FPN ile karşılaştırmışlardır. Tüm ölçümlerde büyük bir farkla ondan daha iyi performans gösterdiğini bulmuşlardır. Bunun nedeni, U-Net'in çok sığ olması, ağımızda kullanılan önceden eğitilmiş omurganın daha güçlü özellikler çıkarabilmesi ve MSFA modülümüzün daha üst düzey özellik füzyonu sağlamasıdır.

Moon J ve ark.[76] bir derin öğrenme sistemini yapay zeka olarak pratik kullanım için 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 göstermişlerdir. 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. Biz de çalışmamızda 1102 veri seti kullandık. Kim ve ark.[77] nın yaptığı çalışma veri seti sayısı en yüksek olan çalışmadır ve eğitim için toplam 3150 lateral sefalogram, harici doğrulama veri seti olarak 100 lateral sefalogram kullanmışlardır. Bizim çalışmamıza oranla daha fazla veri seti olan bu çalışmada kullanılan yapay zeka mimarileri de farklıdır ve diğer bir farkta bizim çalışmamızda 3 boyutlu radyograflardan 2 boyutlu sefalometrik radyograflar elde edilmesidir.

Ugurlu ve ark.[68] 1360 lateral sefalometrik radyograf üzerinde 21 landmark noktasının FAR-net derin öğrenme modeli, Lee ve ark.[75] 400 lateral sefalometrik radyograf üzerinde Bayesian derin öğrenme modelini kullanarak, Kim ve ark.[77] 3150 lateral sefalometrik radyograf üzerinde iki kademeli derin öğrenme modelini kullanarak Sella noktasının en yüksek SDR oranına sahip olduğunu ve konumunun belirlenmesi en kolay nokta olarak sella noktasını tespit etmişlerdir. Bizim çalışmamızda ise Sella noktası diğer noktalara göre düşük bir tespit oranı gösterdi. Bunun sebeplerinden birinin ultra düşük doz aldığımız KIBT görüntülerinden 2 boyutlu görüntüler elde edilmesinin görüntü netliğini azalttığını düşünmekteyiz. Diğer bir sebep olarak orta hatta yer alan kemik

yapıların KIBT görüntülerinde rekonstrüksiyonlarında oluşabilecek hatalardan kaynaklandığını düşünmekteyiz.

Bulatova ve ark.[4] YOLOV3 derin öğrenme modelini kullanarak yapay zekanın landmark tespit başarısını uzman ortodontistlerin manuel landmark tespiti ile karşılaştırdıkları çalışmasında Gonion noktasının yapay zeka ile tespitinde başarısının düşük olduğunu belirtmişlerdir.

Kim M ve ark.[78] CBCT ile sentezlenen 2B lateral ve maksimum yoğunluk görüntüsündeki (MIP görüntüsü) lateral sefalogramlardan oluşan 830 veri setinden oluşturmuş. Çok aşamalı evrişimli sinir ağları (CNN'ler) mimarisine landmark tespiti yapmışlardır. En düşük SDR oranı Gonion noktasında bulmuşlardır.

Bizim çalışmamızda Gonion noktasının başarısı yüksek bulundu. Veri sayımızın diğer çalışmalardan yüksek olmasına ve KIBT görüntülerinden sefalometrik radyografları elde ederken önce kafa oryantasyonunu düzelttiğimiz için noktanın başarı oranı arttığı tahmin etmekteyiz.

Zeng ve ark.[74] 400 sefalometrik radyograf üzerinde 19 landmark tespitini değerlendirmişler. Kim Y ve ark. 950 sefalometrik radyograf üzerinden eğitimli uzmanlar ile yapay zeka derin öğrenme mimarilerinin başarısını karşılaştırmışlar.

İki çalışmada da bizim çalışmamıza benzer olarak kesici kenarların tespiti yapay zeka tarafından algılama oranı yüksek bulunmuştur. Bunu kesici dişlerin radyograflardaki görüntü kalitesinin yüksek olmasın ve sınırlarının keskin bir şekilde belirgin olmasına bağlayabiliriz.

Kim ve ark.[77] farklı makine öğrenme modellerindeki sefalometrik noktaların yaptığı çalışmada eğitilen işaretler arasında, kafatasına ait olanların daha büyük hatalar gösterdiğini tespit etmişlerdir. Bu işaretler diğer anatomik yapılara süperpoze olduğu için, onları lateral sefalogramlarda bulmak zordur. Ek olarak, çene bölgesinin önemli noktaları

daha düşük doğruluk göstermiş. Nedeni, mandibulanın B noktası, pogonion ve menton gibi yer işaretlerinin kavisli bir hat üzerinde yer alan anatomik noktalar olması ve diğer hatlarla ANS veya insizal uç gibi sivri yapıların tanımlanmasına yardımcı olmak için kesişme gibi belirgin özelliklere sahip olmaması olarak tahmin etmişlerdir. Diğer bir olasılık ise, bu yer işaretlerinin görüntü sensörlerinin çevresinde yer alması ve merkezi ışından daha uzak olması, görüntü kalitesinin düşmesine neden olmuş olabileceğidir. Nasion, bazı test verilerinde yüksek hatalar göstermiş bizim çalışmamıza zıt olarak ve bu bazı makineler metal burun desteği parçasına sahip olduğu için nasion noktası net belirlenememiş olabilir. Bu çalışma sadece eğitim için sert doku işaretlerini içeriyordu. Tedavi planlamasında ve tedavi sonuçlarının tahmininde klinik kullanım bizim çalışmamızda olduğu gibi yumuşak doku yer işaretleri de kullanılmalıdır.

Çalışmamızda KIBT görüntülerini kullanma amacımız üst üste binen ve katmanlı bilateral yapıları en aza indirmek için KIBT tarafından sentezlenen lateral sefalogramları kullanmaktı, katmanlı görüntüler hala kafa karıştırıcı değişkenler olarak kaldı. Örneğin, üst üste binen mandibula, özellikle gonionu deşifre etmeyi zorlaştıran asimetrisi olan hastalarda belirgin bir şekilde iki çizgi yaptı. Bu nedenle, telafi olarak, bu kusurları güçlendirmek için Kim M ve ark.[78] çalışmasındaki gibi MIP görüntüsünü kullanılması önerilebilir.

Önceki çalışmalar, konvansiyonel lateral sefalogram ile farklı tipte KIBT sentezlenmiş 2D lateral sefalogramlar arasındaki tekrarlanabilirliği karşılaştırdı. Bu çalışmaların sonucu, KIBT'den sentezlenmiş sefalogramdan elde edilen lineer ve açısal ölçümün geleneksel sefalogramdan daha yüksek tutarlılıkla sonuçlanmasıydı.[79,80] Eğitim için daha başarılı yer işareti noktası tanımlaması gerçekleştirmek için KIBT sentezlenmiş kombinasyon verilerini kullandık.

KIBT şu anda 3D bilgi sağlamak için kullanılmasına rağmen, daha ileri çalışmalar sefalometride daha iyi standardizasyona yol açacaktır. Doğrudan yer işareti belirleme ve ölçme yeteneği eksikti. Mevcut araştırmaya dayalı analizleri kullanmak için hastalardan 3B görüntüler elde etmemize rağmen, bunun 2B boyuta dönüştürülmesi gerekiyordu.[81,82] Falk Schwendiche ve ark.[73] yaptığı sistematik derleme ve meta analizde DL'nin sefalometrik radyograflarda landmark tespit etme doğruluğunu araştırmışlar. İncelediklerı tüm çalışmalarda CNN'ler kullanıldı, Mevcut sistematik inceleme ve meta-analiz, sefalometrik 2-D veya 3-D radyograflarda landmark noktası tespiti için DL kullanan çalışmaları değerlendirmişlerdir.

Anlamlı sonuçlar elde etmek için, yer işaretlerinin kesin olarak tanımlanması çok önemlidir.[83] Mevcut inceleme, 2-D veya 3-D sefalometrik görüntülerde işaret noktası tespiti için DL kullanan çalışmaları değerlendirmiş. Dahil edilen 19 çalışmaya dayanarak, DL'yi bu amaç için doğru bulmuşlar; çalışmaların çoğu, ortalama olarak 2 mm'lik bir tahmin hatası eşiğini aşmamış ve bu 2 mm'lik eşik içinde tespit edilen yer işaretlerinin ortalama oranı %80 olarak bulunmuş. Bizim çalışmamızda 2 mm'lik eşik içinde 44 noktadan 33 tanesinde tespit oranı yüzde 90'nın üzerindeydi. 4 mm'lik eşik içerisinde ise belirlediğimiz noktaların yarısı yüzde yüz başarı gösterdi.

Genel olarak ve insan karşılaştırma gruplarını DL'ye karşı değerlendiren iki çalışmaya dayanarak, DL'nin normal klinisyenlere benzer[26] ve hatta deneyimsiz olanlardan daha üstün olduğu sonucuna varmışlar.[84]

İkinci olarak, 3 boyutlu görüntülere ilişkin veriler seyrekti; Yakın tarihli bir sistematik derleme, DL'yi 3-D dönüm noktası tespiti için bilgi ve yüzeysel öğrenmeye dayalı yöntemlerle karşılaştırdı ve DL'nin en doğru olduğu sonucuna vardı.[85] Bununla birlikte, verilerdeki yetersizlik göz önüne alındığında, şu anda 3 boyutlu yer işareti tespiti için DL'yi güçlü bir şekilde onaylamak zordur. Biz çalışmamızda 3 boyutlu görüntüler

üzerinden değil 3 boyutlu görüntüden elde ettiğimiz 2 boyutlu radyograflar üzerinde landmark tespiti yapılmıştır. Çalışmamız 3 boyutlu landmark tespiti için öncül çalışmalardan biri sayılabilir.

Genel olarak, KIBT temelli değerlendirmelerin birçok ortodontik hasta için kural olmayacağı, örneğin ortognatik cerrahi planlanırken istisna olacağı düşünülmelidir [86]. Daha büyük veri kümeleri, daha güçlü donanımlar ve daha etkili DL mimarileri mevcut olabileceğinden, daha yeni çalışmaların daha yüksek doğruluklar göstermesi beklenebilir.[87]

DL, sefalometrik görüntülerde yer işaretlerini tespit etmek için nispeten yüksek doğruluk gösterir. Çalışmaların çoğu 2 boyutlu görüntülere odaklanmış; 3 boyutlu görüntülere ilişkin veriler seyrektir, ancak umut vericidir. Yer işaretleri arasında tespit doğruluğunda heterojenlik vardır ve klinisyenlerin farklı işaretler için DL'den daha fazla veya daha az doğru olup olmadığı belirsizliğini koruyor. Genel kanıtlar, büyük ölçüde tutarlı olmakla birlikte, sınırlı genellenebilirlik ve sağlamlığa sahiptir ve klinik bakımda DL kullanmanın gerçek değerinin gösterilmesi gerekmektedir.

Bu çalışmada ortodontik tanı ve tedavi planını belirlemek amacıyla kullandığımız sefalometrik noktaların bir yapay zeka programı ile otomatik olarak işaretleyebilen program kullandık.10 adet dişşel nokta,16 adet yumuşak doku noktası ve 28 adet iskeletsel nokta işaretledik. Dişsel noktaların 2 mm'lik aralıkta SDR değeri % 94'ün üzerindeydi.En düşük SDR oranı Pterydoid ve Glabella noktasında elde edildi. Bunun sebebi Pterygoid noktasının daha çok sanal olarak oluşturulan sınırlar içerisinde işaretlenmesi olabilir. Glabella noktası içinse KIBT görüntülerinin bazılarında görüntünün Glabella noktasının alt sınırından başlıyor olması sebebiyle bazı görüntülerde Glabella noktası tespit edilmesindeki zorluktan kaynaklı olduğunu düşünmekteyiz.

Çalışmamızda artefaktlı görüntüler, kraniofasiyal sendromu, dudak damak yarığı, kraniofasiyal bölge kemik hastalıkları olan hastalar, protetik restorasyon ve dental implanta sahip hastalar ve diş eksikliği olan, ortognatik cerrahi görmüş hastaların görüntüleri veri setine dahil edilmedi. Çalışmamızın dar bir popülasyonda yapılmış olması limitasyonumuzdur.

Çalışmamızda veri setini oluşturan bütün görüntüler aynı KIBT cihazında, aynı parametrelerle çekilen görüntülerden oluşmaktadır. Ve dolphin programında aynı şekilde oryante edilmiştir. 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. SONUÇLAR VE ÖNERİLER

Geliştirdiğimiz AI algoritmalarının KIBT görüntülerinden elde ettiğimiz 2 boyutlu sefalometrik radyograflar üzerindeki iskeletsel, dişsel noktaları ve yumuşak doku noktalarının tespit sonuçları umut vericidir. Çalışmada eğitilen AI modelinde SDR değerleri 2 mm'lik aralıkta 4 nokta haricinde yüzde 80 üzerinde değerler gösterdi.

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. Moyers RE, Bookstein FL. The inappropriateness of conventional cephalometrics. Am J Orthod 1979;75(6):599-617.
2. Kumar V, Ludlow JB, Mol A, Cevidanes L. Comparison of conventional and cone beam CT synthesized cephalograms. Dentomaxillofac Radiol 2007;36(5):263-9.
3. Uzel İ, Enacar A. Ortodontide Sefalometri. 2. Baskı. Ankara: 2000. p.3-210.
4. 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.
5. Papadopoulos MA, Christou PK, Christou PK, Athanasiou AE, Boettcher P, Zeilhofer HF, Sader R, Papadopulos NA. Three-dimensional craniofacial reconstruction imaging. Oral Surg Oral Med Oral Pathol Oral Radiol Endod 2002;93(4):382-93.
6. B. Holly Broadbent; A New X-Ray Technıque *And* Its Applıcatıon To Orthodontıa. *Angle Orthod* 1931; 1 (2): 45–66.
7. 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.
8. Ricketts RM. Cephalometric analysis and synthesis. Angle Orthod 1961;31(3):141-56.
9. Graber, Thomas M., Robert L. Vanarsdall Jr, and K. W. Vig. "Orthodontics. Current principles & techniques." Eur J Orthod 2006. p.197.
10. Månsson S, Johansson E, Magnusson P, Chai CM, Hansson G, Petersson JS, Ståhlberg F, Golman K. 13C imaging-a new diagnostic platform. Eur Radiol 2006 Jan;16(1):57-67.
11. Edwards MK. Magnetic resonance imaging of the head and neck. Dent Clin North Am 1993;37(4):591–611.
12. Baumrind S, Peltzman P, Moffitt FH. New system for integrated three dimensional craniofacial mapping. J Dent Res 1971;50(6):1496-7.
13. Üçok Ö, Kayadüğün A. Ortdontide Konik Işınlı Bilgisayarlı Tomografi Endikasyonları. Güncel Bilgiler Işığında Ortodonti, E Özdiler, editör. 1. Baskı. Ankara:283.

14. White SC. Cone-beam imaging in dentistry. Health Phys. 2008;95(5):628–637.
15. Topsakal Kg, Korkmaz Yn. Ortodontide Üç Boyutlu Görüntüleme Sistemleri: Literatür Derlemesi. Selcuk Dental Journal 2018;5(2):186–93.
16. Pathak S, Mishra N, Rastogi MK, Sharma S. Significance of radiological variables studied on orthopantamogram to pridict post-operative inferior alveoler nerve paresthesia after third molar extraction. J Clin Diagn Res 2014;8(5):62-4.
17. Mah JK, Danforth RA, Bumann A, Hatcher D. Radiation absorbed in maxillofacial imaging with a new dental computed tomography device. Oral Surg Oral Med Oral Pathol Oral Radiol Endod 2003;96(4):508-13.
18. Herring Jt. The Effectıveness Of Orthodontists And Oral Radiologists In The Diagnosis Of Impacted Maxillary Canines. Department of Orthodontics. Master thesis, University of North Carolina,2006.
19. Honda K, Larheim TA, Maruhashi K, Matsumoto K, Iwai K. Osseous abnormalities of the mandibular condyle: diagnostic reliability of cone beam computed tomography compared with helical computed tomography based on an autopsy material. Dentomaxillofac Radiol 2006;35(3):152-7.
20. Tsiklakis K, Syriopoulos K, Stamatakis HC. Radiographic examination of the temporomandibular joint using cone beam computed tomography. Dentomaxillofac Radiol 2004;33(3):196-201.
21. Domeshek LF, Mukundan S, Yoshizumi T, Marcus JR. Increasing concern regarding computed tomography irradiation in craniofacial surgery. Plast Reconstr Surg 2009;123(4):1313–20.
22. De Moraes ME, Hollender LG, Chen CS, Moraes LC, Balducci I. Evaluating craniofacial asymmetry with digital cephalometric images and cone-beam computed tomography. Am J Orthod Dentofacial Orthop 2011 Jun;139(6):523-31.
23. Jakobsone G, Neimane L, Krumina G. Two- and three-dimensional evaluation of the upper airway after bimaxillary correction of Class III malocclusion. Oral Surg Oral Med Oral Pathol Oral Radiol Endod 2010;110(2):234-42.
24. Mah JK, Huang JC, Choo H. Practical applications of cone-beam computed tomography in orthodontics. J Am Dent Assoc 2010 Oct;141 Suppl 3:7-13.
25. Leonardi R, Giordano D, Maiorana F, Spampinato C. Automatic Cephalometric AnalysisA Systematic Review. Angle Orthod 2008;78(1):145–51.

26. Liu JK, Chen YT, Cheng KS. Accuracy of computerized automatic identification of cephalometric landmarks. Am J Orthod Dentofacial Orthop 2000;118(5):535-40.
27. Chen SK, Chen YJ, Yao CC, Chang HF. Enhanced speed and precision of measurement in a computer-assisted digital cephalometric analysis system. Angle Orthod 2004;74(4):501-7.
28. Brennan J. An introduction to digital radiography in dentistry. J Orthod 2002;29(1):66–9.
29. Quintero JC, Trosien A, Hatcher D, Kapila S. Craniofacial imaging in orthodontics: historical perspective, current status, and future developments. Angle Orthod 1999;69(6):491-506.
30. Gravely JF, Benzies PM. The clinical significance of tracing error in cephalometry. Br J Orthod 1974;1(3):95–101.
31. Vithanaarachchi N 5th, Chandrasiri A C, Nawarathna L N. A comparison of cephalometric measurements obtained using conventional and digital methods. Ceylon Med J 2020;65(3):39-45.
32. 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):105–8.
33. Shapiro, Stuart C. Encyclopedia Of Artificial İntelligence. *New Jersey: A Wiley Interscience Publication*, 2.nd ed. 1992.
34. Ramesh AN, Kambhampati C, Monson JRT, Drew PJ. Artificial intelligence in medicine. Ann R Coll Surg Engl 2004;86(5):334–8.
35. Khanagar SB, Al-ehaideb A, Maganur PC et al. Developments, application, and performance of artificial intelligence in dentistry – A systematic review. J Dent Sci 2021;16(1):508–22.
36. Samuel AL. Some Studies in Machine Learning Using the Game of Checkers. II—Recent Progress. *IBM J Res Dev* 2010;11(6):601–17.
37. Nichols JA, Herbert Chan HW, Baker MAB. Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophys Rev*. 2019;11(1):111–8.
38. Steimann F. On the use and usefulness of fuzzy sets in medical AI. Artif Intell Med 2001;21(1-3):131-7.
39. Ramesh AN, Kambhampati C, Monson J, Drew PJ. Artificial intelligence in medicine. *Ann R Coll Surg Engl* 2004;86.

40. Öztürk K, Şahin M.E, Yapay Sinir Ağları ve Yapay Zekaya Genel Bir Bakış, Takvim-i Vekayi, 2018;6(2):25-36
41. Lee JG, Jun S, Cho YW et al. Deep Learning in Medical Imaging: General Overview. *Korean J Radiol* 2017;18(4):570–84.
42. Başaran E. Timpanik Membran Görüntü Analizi ve Yapay Zeka Kullanılarak Sanal Otitis Media Tanı Sisteminin Geliştirilmesi. Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği. Doktora Tezi, Karabük: Karabük Üniversitesi, 2020.
43. Öztemel, E. Yapay Sinir Ağları. 2. Baskı. İstanbul:Papatya Yayıncılık.
44. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Sci Dent* 2019;49(1):1–7.
45. Burt JR, Torosdagli N, Khosravan N et al. Deep learning beyond cats and dogs: recent advances in diagnosing breast cancer with deep neural networks. *Br J Radiol* 2018;91(1089).
46. Aminoshariae A, Kulild J, Nagendrababu V. Artificial Intelligence in Endodontics: Current Applications and Future Directions. *J Endod* 2021;47(9):1352–7.
47. Ağyar, Z. Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama. Mühendis ve Makine.2015;56(662), 22-3.
48. Elmas Ç. *Yapay Sinir Ağları*. 1. Baskı. Ankara: 2003.
49. Suzuki K. Overview of deep learning in medical imaging. Radiol Phys Technol 2017;10(3):257-73.
50. Murphy KP. Machine learning: a probabilistic perspective. MIT press. 2012;1-16.
51. Üzen H, Hanbay K. Yaya Özellik Tanıma için LM Filtre Temelli Derin Evrişimsel Sinir Ağı. J Polytech 2019;0900(3):605–13.
52. Chen CY, Lin YT, Lee SJ, Tsai WC, Huang TC, Liu YH, Cheng MC, Dai CY. Automated ECG classification based on 1D deep learning network.2022;20(2):127-35.
53. İnik Ö. Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri.*GBAD* 2017;6(3):85–104.
54. ZahediNasab R, Mohseni H. Neuroevolutionary based convolutional neural network with adaptive activation functions. *Neurocomputing* 2020;38(1):306–13.
55. Han D, Liu Q, Fan W. A new image classification method using CNN transfer learning and web data augmentation. Expert Syst Appl 2018;95(3)43–56.

56. Yu HJ, Cho SR, Kim MJ, Kim WH, Kim JW, Choi J. Automated Skeletal Classification with Lateral Cephalometry Based on Artificial Intelligence. *J Dent Res* 2020;99(3):249–56.
57. 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):41
58. 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):262-6.
59. Choi HI, Jung SK, Baek SH, Lim WH, Ahn SJ, Yang IH, Kim TW. Artificial Intelligent Model With Neural Network Machine Learning for the Diagnosis of Orthognathic Surgery. J Craniofac Surg 2019;30(7):1986-9.
60. Cohen AM, Ip HH, Linney AD. A preliminary study of computer recognition and identification of skeletal landmarks as a new method of cephalometric analysis. Br J Orthod 1984;11(3):143-54.
61. Lévy-Mandel AD, Venetsanopoulos AN, Tsotsos JK. Knowledge-based landmarking of cephalograms. *Comput Biomed Res* 1986;19(3):282–309.
62. Jeon S, Lee KC. Comparison of cephalometric measurements between conventional and automatic cephalometric analysis using convolutional neural network. Prog Orthod 2021;22(1):14.
63. Hwang HW, Park JH, Moon JH, Yu Y, Kim H, Her SB, Srinivasan G, Aljanabi MNA, Donatelli RE, Lee SJ. Automated identification of cephalometric landmarks: *Part 2-Might it be better than human?* Angle Orthod 2020;90(1):69-76.
64. Ao Y, Wu H. Feature Aggregation and Refinement Network for 2D Anatomical Landmark Detection. J Digit Imaging 2022;18.
65. Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. 2014.
66. He, K., Zhang, X., Ren, S. and Sun, J. Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016;770-8.
67. Huang G, Liu Z, van der Maaten L, Weinberger KQ. Densely connected convolutional networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017; 4700–08.

68. Uğurlu M. Performance of a Convolutional Neural Network- Based Artificial Intelligence Algorithm for Automatic Cephalometric Landmark Detection. *Turk J Orthod* 2022;35(2):94–100.
69. Aşçi E, Kiliç M, Çelik Ö. Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zekâ Yöntemi ile Panoramik Radyografilerde Dental Restorasyonların Otomatik Tespiti ve Sınıflandırılması: Metodolojik Çalışmalar. Türkiye Klinikleri J Dental Sci 2022;28(2):329-37.
70. 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.
71. 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.
72. Casalegno F, Newton T, Daher R et al. Caries detection with near-infrared transillumination using deep learning. J Dent Res. 2019;98(11):1227–33.
73. Schwendicke F, Chaurasia A, Arsiwala L et al. Deep learning for cephalometric landmark detection: systematic review and meta-analysis. Clin Oral Investig 2021;25(7):299–309.
74. Zeng M, Yan Z, Liu S, Zhou Y, Qiu L. Cascaded convolutional networks for automatic cephalometric landmark detection. Med Image Anal. 2021;68(10):194.
75. 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):270.
76. 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.
77. Kim J, Kim I, Kim Y et al. Accuracy of automated identification of lateral cephalometric landmarks using cascade convolutional neural networks on lateral cephalograms from nationwide multi-centres. Orthod Craniofac Res 2021;24(2)59–67.
78. Kim M-J, Liu Y, Oh SH, Ahn H-W, Kim S-H, Nelson G. Automatic cephalometric landmark identification system based on the multi-stage convolutional neural networks with CBCT combination images. Sensors. 2021;21(2):505.

79. Navarro Rde L, Oltramari-Navarro PV, Fernandes TM, Oliveira GF, Conti AC, Almeida MR, Almeida RR. Comparison of manual, digital and lateral CBCT cephalometric analyses. J Appl Oral Sci 2013;21(2):167-76.
80. Smektała T, Jędrzejewski M, Szyndel J, Sporniak-Tutak K, Olszewski R. Experimental and clinical assessment of three-dimensional cephalometry: a systematic review. J Craniomaxillofac Surg 2014;42(8):1795-801.
81. Park C-S, Park J-K, Kim H, Han S-S, Jeong H-G, Park H. Comparison of conventional lateral cephalograms with corresponding CBCT radiographs. Imaging Sci Dent 2012;42(4):201–5.
82. Gribel BF, Gribel MN, Manzi FR, Brooks SL, McNamara JA Jr. From 2D to 3D: an algorithm to derive normal values for 3-dimensional computerized assessment. Angle Orthod 2011;81(1):3-10.
83. Baumrind S, Frantz RC. The reliability of head film measurements. 1. Landmark identification. Am J Orthod 1971;60(2):111-27.
84. Muraev AA, Tsai P, Kibardin I, Oborotistov N, Shirayeva T, Ivanov S, Ivanov S, Guseynov N, Aleshina O, Bosykh Y, Safyanova E, Andreischev A, Rudoman S, Dolgalev A, Matyuta M, Karagodsky V, Tuturov N. Frontal cephalometric landmarking: humans vs artificial neural networks. Int J Comput Dent 2020;23(2):139-48.
85. Dot G, Rafflenbeul F, Arbotto M, Gajny L, Rouch P, Schouman T. Accuracy and reliability of automatic three-dimensional cephalometric landmarking. Int J Oral Maxillofac Surg 2020;49(10):1367–78.
86. American Academy of Oral and Maxillofacial Radiology. Clinical recommendations regarding use of cone beam computed tomography in orthodontics. Position statement by the American Academy of Oral and Maxillofacial Radiology. Oral Surg Oral Med Oral Pathol Oral Radiol 2013;116(2):238–57.
87. Huang Y, Fan F, Syben C, Roser P, Mill L, Maier A. Cephalogram synthesis and landmark detection in dental cone-beam CT systems. Med Image Anal 2021;70(10):20-8.

EKLER

EK-1. ÖZGEÇMİŞ

1. KİŞİSEL BİLGİLER

ADI SOYADI	Seda Saliha KAYRAK
HALEN GÖREVİ	Araştırma Görevlisi (Araş.Gör. Seda Saliha KAYRAK)

2. EĞİTİM

YILI	DERECESİ	ÜNİVERSİTE	ÖĞRENİM ALANI

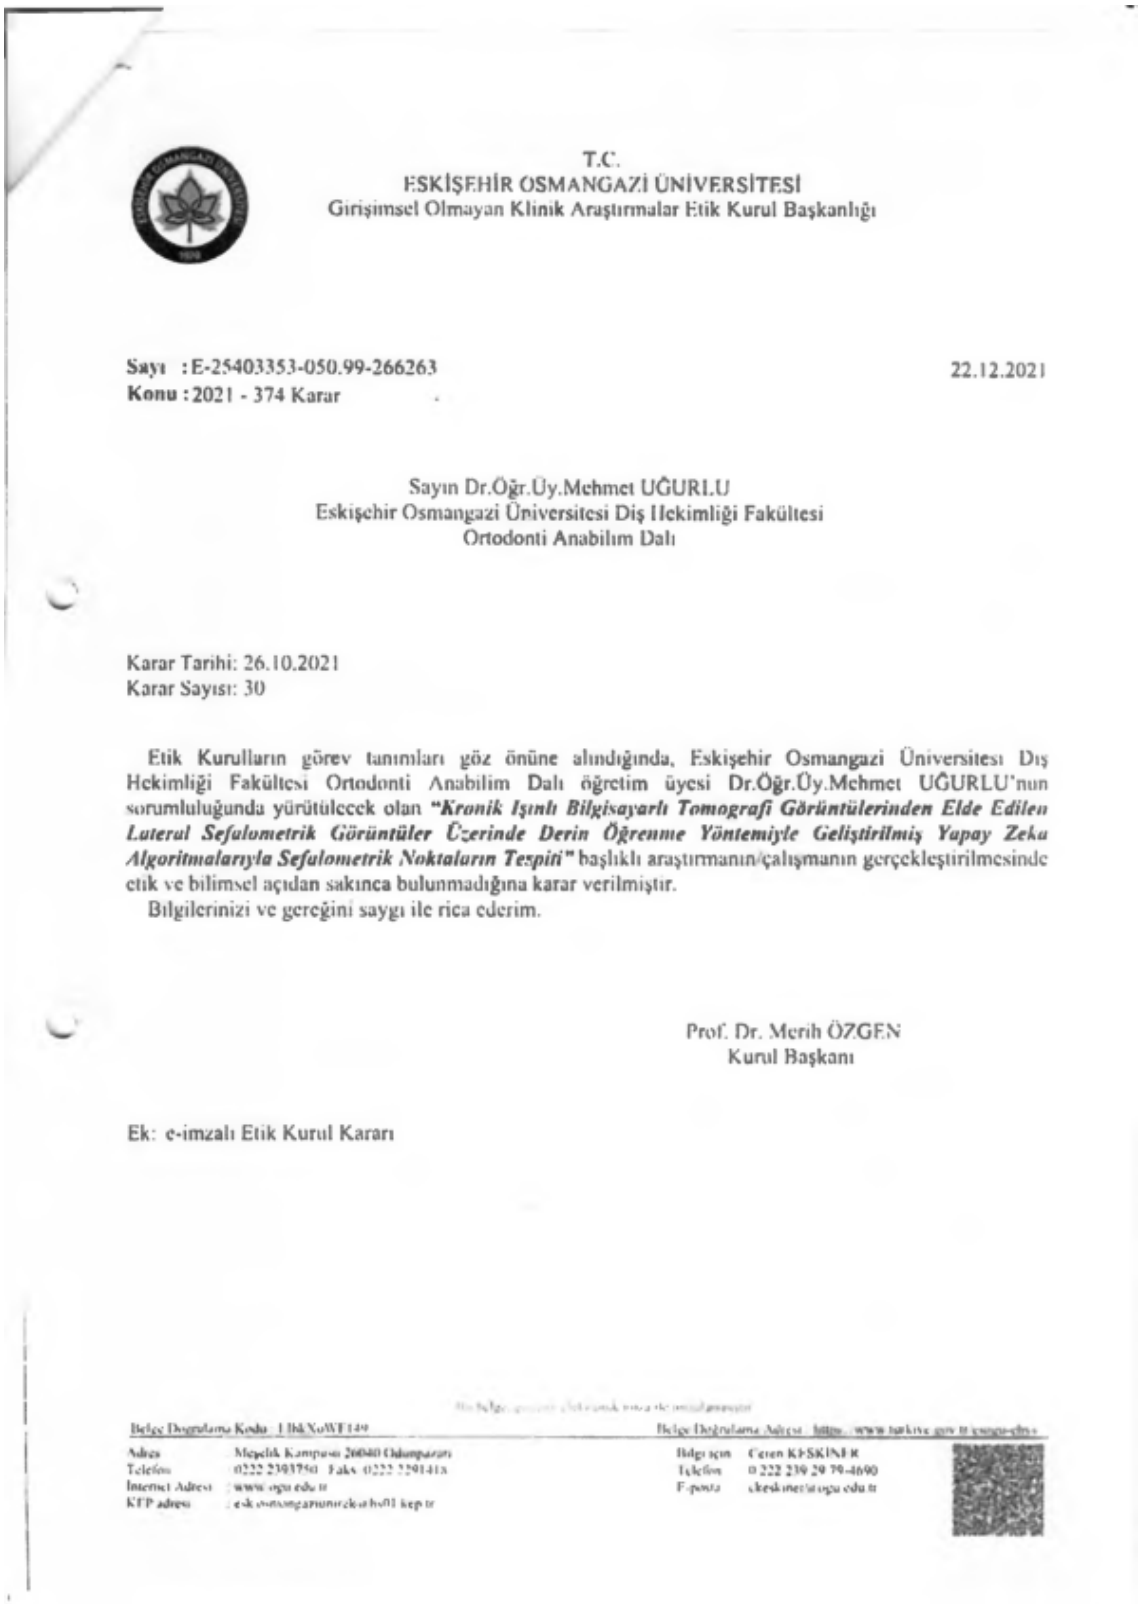
3. AKADEMİK DENEYİM

GÖREV DÖNEMİ	ÜNVAN	BÖLÜM	ÜNİVERSİTE

4. ÇALIŞMA ALANLARI

ÇALIŞMA ALANI	ANAHTAR SÖZCÜKLER
Ortodonti	Ortodonti

EK-2. ETİK KURUL ONAYI



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

Sayı : E-25403353-050.99-266263 22.12.2021
Konu : 2021 - 374 Karar

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

Karar Tarihi: 26.10.2021
Karar Sayısı: 30

Etik Kurulların görev tanımları göz önüne alındığında, Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı öğretim üyesi Dr.Öğr.Üy.Mehmet UĞURLU'nun sorumluluğunda yürütülecek olan ***"Kronik Işınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Lateral Sefalometrik Görüntüler Üzerinde Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometrik Noktaların Tespiti"*** başlıklı araştırmanın/çalışmanın 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

Belge Doğrulama Kodu: [illegible] Belge Doğrulama Adresi: https://www.turkiye.gov.tr/[illegible]

Adres : Meşelik Kampüsü 26040 Odunpazarı
Telefon : 0222 2393750 Faks: 0222 2391413
İnternet Adresi : www.ogu.edu.tr
KEP adresi : eskisehirosmangaziuniversitesi@hs01.kep.tr

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

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

Prof.Dr.Metin 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
Halk 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.Gökmar 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.Zerrin BARIŞ
Eskişehir Osmangazi Üniversitesi
Tıp Fakültesi
Çocuk Sağlığı ve Hastalıkları AD
Çocuk Gastroenterolojisi BD

Doç.Dr.Mustafa Doğer 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

KARAR FORMU

Başvuru Tarihi: 23.09.2021	**Çalışmanın Başlığı:** *"Kronik Işınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Lateral Sefalometrik Görüntüler Üzerinde Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometrik Noktaların Tespiti"* **Çalışmacılar:** Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı - Dr.Öğr.Üy.Mehmet UĞURLU (Tez Danışmanı), Arş.Gör.Dt.Seda Saliha KAYRAK (Tez Sahibi)
Çalışmanın değerlendirildiği ilk toplantı tarihi: 26.10.2021	**Sonuç:** 1. Kişisel sağlık verileri kimliği belirli veya belirlenebilir gerçek kişiye ilişkin her türlü sağlık bilgisi olduğundan, kişisel sağlık verilerinin işlenmesi ile ilgili olarak ilgili mevzuat hükümleri dikkate alınmalı, verilerin yetkisiz kişilerin eline geçmesi önlenmelidir. Araştırmacıların kurulumuza taahhütnamelerle iletmiş oldukları sorumlulukları yerine getirmeleri beklenmektedir. 2. Kurum izinlerinin alınması araştırmacıların sorumluluğunda olup, ilgili kurumdan alınan izin yazılarının kurulumuza iletilmesi gerekmektedir.
Karar Tarihi: 26.10.2021 **Karar No:** 30	Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ortodonti Anabilim Dalı öğretim üyesi Dr.Öğr.Üy.Mehmet UĞURLU'nun sorumluluğunda yürütülecek olan ***"Kronik Işınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Lateral Sefalometrik 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.

Etik Kurul Sekreterliği
Ceren Kırmızıdır
Tel: 0 Bu belge güvenli elektronik imza ile imzalanmıştır.
Belge Doğrulama Kodu : liKmfz2d177

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

Çalışmanın Başlığı: *"Kronik İşınlı Bilgisayarlı Tomografi Görüntülerinden Elde Edilen Lateral Sefalometrik Görüntüler Üzerinde Derin Öğrenme Yöntemiyle Geliştirilmiş Yapay Zeka Algoritmalarıyla Sefalometrik Noktaların Tespiti"*

GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU

	Unvanı/Adı/Soyadı	Kurumu	İmza
1	Prof.Dr Metin ÖZGEN (Başkan)	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Fizik Tedavi ve Rehabilitasyon AD	*e-imzalıdır*
2	Prof.Dr Hava ÜSKÜDAR TEKE (Başkan Yardımcısı)	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi İç Hastalıkları AD - Hematoloji BD	*e-imzalıdır*
3	Doç.Dr Ferdi KOŞGER (Raportör)	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Ruh Sağlığı ve Hastalıkları AD	*e-imzalıdır*
4	Prof.Dr.Ömür ŞAYLIGİL	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Tıp Tarihi ve Etik AD	-
5	Prof.Dr.Setenay DİNÇER ÖNER	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Biyoistatistik AD	*e-imzalıdır*
6	Prof.Dr.Özlem ÖRSAL	Eskişehir Osmangazi Üniversitesi Sağlık Bilimleri Fakültesi Halk Sağlığı Hemşireliği AD	*e-imzalıdır*
7	Prof.Dr.Suzan ŞAYLISOY	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Radyoloji AD	-
8	Doç.Dr Göknur YORULMAZ	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi İç Hastalıkları AD Endokrinoloji ve Metabolizma Hastalıkları BD	*e-imzalıdır*
9	Doç.Dr Muhammed Fatih ÖNSÜZ	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Halk Sağlığı AD	*e-imzalıdır*
10	Doç.Dr Melih VELİPAŞAOĞLU	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Kadın Hastalıkları ve Doğum AD	*e-imzalıdır*
11	Doç.Dr Zeren BARIŞ	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Çocuk Sağlığı ve Hastalıkları AD Çocuk Gastroenterolojisi BD	*e-imzalıdır*
12	Doç.Dr Mustafa Değer BİLGEÇ	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Göz Hastalıkları AD	*e-imzalıdır*
13	Doç.Dr Ömür DERECİ	Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Cerrahisi AD	*e-imzalıdır*
14	Dr Öğr.Üy F Nazlı DURMAZ ÇELİK	Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Nöroloji AD	-
15	Av Önder CAN	Hukuk	-

E-imzalıdır
Bu belge, güvenli elektronik imza ile imzalanmıştır.
Belge Doğrulama Kodu : liKmfe2d177