



**TÜRKİYE CUMHURİYETİ
ANKARA ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ**



**KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE
NAZOPALATİN KANAL TESPİTİNİN YAPAY ZEKA İLE
KARŞILAŞTIRILMASI**

Hatice Ahsen DENİZ

**AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI
UZMANLIK TEZİ**

**DANIŞMAN
Prof. Dr. Rana NALÇACI**

**ANKARA
2023**

TÜRKİYE CUMHURİYETİ
ANKARA ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE
NAZOPALATİN KANAL TESPİTİNİN YAPAY ZEKA İLE
KARŞILAŞTIRILMASI

Hatice Ahsen DENİZ

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI
UZMANLIK TEZİ

DANIŞMAN
Prof. Dr. Rana NALÇACI

ANKARA
2023

ETİK BEYAN

Ankara Üniversitesi

Diş Hekimliği Fakültesi Dekanlığı'na,

Uzmanlık tezi olarak hazırlayıp sunduğum “Konik Işınlı Bilgisayarlı Tomografi Görüntülerinde Nazopalatin Kanal Tespitinin Yapay Zeka ile Karşılaştırılması” başlıklı tez, bilimsel ahlak ve değerlere uygun olarak tarafımdan yazılmıştır. Tezimin fikir/hipotezi tümüyle tez danışmanım ve bana aittir. Tezde yer alan klinik çalışma tarafımdan yapılmış olup, tüm yorumlar bana aittir.

Yukarıda belirtilen hususların doğruluğunu beyan ederim.

Uzmanlık Öğrencisinin Adı Soyadı: Hatice Ahsen DENİZ

Tarih:10/01/2023

İmza:

KABUL VE ONAY

Ankara Üniversitesi Diş Hekimliği Fakültesi

Ağız, Diş ve Çene Radyolojisi Uzmanlık Programı

çerçevesinde yürütölmüş olup bu çalışma, aşğıdaki jüri tarafından

Uzmanlık Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi:

10/01/2023

Prof. Dr. Kaan ORHAN

Ankara Üniversitesi

Diş Hekimliği Faköltesi

Ağız, Diş ve Çene Radyolojisi

A.B.D.

Jüri Başkanı

Prof. Dr. Rana NALÇACI

Ankara Üniversitesi

Diş Hekimliği Faköltesi

Ağız, Diş ve Çene Radyolojisi A.B.D.

Doç. Dr. Melda MISIRLIOĞLU

Kırıkkale Üniversitesi

Diş Hekimliği Faköltesi

Ağız, Diş ve Çene Radyolojisi A.B.D.

İÇİNDEKİLER

Etik Beyan	i
Kabul ve Onay	ii
İçindekiler	iii
Önsöz	iv
Simgeler ve Kısaltmalar	vi
Şekiller	viii
Çizelgeler	ix
1. GİRİŞ	1
1.1. Nazopalatin Kanal	1
1.1.1. Nazopalatin Kanalin Anatomisi	1
1.1.2. Nazopalatin Kanalin Morfolojisi ve Varyasyonları	4
1.1.3. Nazopalatin Kanalin Klinik Önemi	7
1.1.4. Nazopalatin Kanalin Radyolojik Görüntülenmesi	12
1.1.4.1. Konik Işınli Bilgisayarli Tomografi	13
1.2. Yapay Zeka	14
1.2.1. Yapay Zeka'ya Giriş	14
1.2.2. Makine Öğrenimi	16
1.2.2.1. Yapay Sinir Ağları	17
1.2.2.1.1. Derin Öğrenme ve Derin Evrişimli Sinir Ağları	17
1.2.2.1.1.1. YOLO (You Only Look Once) ve YOLOv5 (You Only Look Once-version 5)	21
1.2.3. Yapay Zekanın Diş Hekimliği ve Ağız, Diş ve Çene Radyolojisinde Kullanım Alanları	21
2. GEREÇ VE YÖNTEM	25
2.1. Veri Setlerinin Oluşturulması	25
2.1.1. Görüntülerin Seçilmesi	25
2.1.2. Kesitlerin Hazırlanması	26
2.2. Görüntülerin Değerlendirilmesi ve Etiketlenmesi	27
2.3. Yapay Zeka Modeli ve Eğitilmesi	28
2.4. Yapay Zekanın Performansının Değerlendirilmesi	31
2.5. Performans Değerlendirme Metrikleri	32
2.6. Gözlemci İçi Güvenilirlik	34
3. BULGULAR	35
4. TARTIŞMA	39
5. SONUÇ VE ÖNERİLER	48
ÖZET	50
SUMMARY	51
KAYNAKLAR	52
EKLER	73
Ek 1-Etik Kurul Kararı	73
Ek 2- Aydınlatılmış Onam Formu	74
ÖZGEÇMİŞ	77

ÖNSÖZ

Uzmanlık eğitimine başladığım ilk andan itibaren bana sevgi ile yaklaşan, desteğini her daim hissettiren, bana asistanlık ve tez dönemim boyunca mesleki anlamda çok şey katan çok saygıdeğer hocam ve tez danışmanım Prof. Dr. Rana NALÇACI'ya;

Tez çalışmamın kurgulanması ve tamamlanmasında destek ve yardımlarını esirgemeyen, bana çok kıymetli bir fırsat sunan çok değerli hocalarım Prof. Dr. Kaan ORHAN'a, Doç. Dr. İbrahim Şevki BAYRAKDAR'a ve Doç. Dr. Elif BİLGİR'e;

Bizlere bir aile ferdi gibi davranan, bilgi ve birikimlerinden hep çok faydalandığımız çok değerli hocalarım Prof. Dr. Candan S. PAKSOY'a, Prof. Dr. Bengi ÖZTAŞ'a, Prof. Dr. Sebahat GÖRGÜN'e, Prof. Dr. Kıvanç KAMBUROĞLU'na ve Prof. Dr. M. Eray KOLSUZ'a;

Her daim bilgi birikimlerinden faydalandığımız ve bizlere akademik hayatımıza dair hep yol gösteren çok kıymetli hocalarım Doç. Dr. M. Hakan KURT'a ve Doç. Dr. Hakan EREN'e;

Birlikte çalışma fırsatı bulduğum için mutluluk duyduğum, asistanlığıma ilk başladığım dönemden itibaren bana çok yardımları dokunan değerli kıdemlim Öğr. Gör. Dt. Cengiz EVLİ'ye;

Önce kıdemlim sonra çok yakın arkadaşım olan, bir şeyler paylaşmaktan çok keyif aldığım, çok değerli kıdemlim Öğr. Gör. Dt. Nur HACIOSMANOĞLU'na;

Beraber çalışmayı keyifli hale getiren, aynı zamanda çok sevdiğim asistan arkadaşlarım Dt. S. Tuğçe GÖKDENİZ'e, Dt. Merve ÖNDER'e, Dt. Zehra İrem ÖZTÜRK'e, Dt. Özgür KARAMAN İNCEKÜRK'e, Dt. Buket EREN'e, Dt. Sena ÇELEBİ'ye, Dt. İrem ÖZTÜRK'e, Dt. Serhat EFEOĞLU'na, Dt. Emre KARAHAN'a ve Dt. Abdullah AKTAŞ'a;

Uzmanlık eğitimine beraber adım attığım, eşkıdemlilerimden öte dostlarım olan, her türlü zorlukta destek olmaktan çekinmeyen çok kıymetli eşkıdemlilerim Uzm. Dt. Elif POLAT BALKAN'a ve Uzm. Dt. Burak İNCEBEYAZ'a;

Çalışma koşullarımızı bizim için güzelleştiren değerli Anabilim Dalı'mızın personellerine;

Hayatım boyunca bana her konuda destek olan, kararlarım saygı duyan, sevgi ve ilgilerini asla esirgemeyen, mesleki anlamda da bana ilk rol modeller olan çok kıymetli annem Uzm. Dr. Berrin ÖZTİMUR DENİZ'e, babam Uzm. Dr. Mustafa Muammer DENİZ'e ve ablam Uzm. Dr. Nuriye Gökçen DENİZ YALÇIN'a;

Mutluluk kaynağım olan ve hayatımı güzelleştiren canım yeğenlerim Elif Sena YALÇIN'a ve Gökalp YALÇIN'a

Sonsuz saygı ve teşekkürlerimi sunarım.

SİMGELER VE KISALTMALAR

%	Yüzde
µm	Mikrometre
2B	İki Boyutlu
3B	Üç Boyutlu
AP	Ortalama Kesinlik (Average Precision)
ark.	Arkadaşları
AUC	ROC Eğrisi Altında Kalan Alan (Area Under Curve)
BT	Bilgisayarlı Tomografi
DESA	Derin Evrişimli Sinir Ağı
DICOM	Digital Imaging and Communications in Medicine
ESA	Evrişimli Sinir Ağı
FN	Yanlış Negatif
FOV	Görüntüleme Alanı (Field Of View)
FP	Yanlış Pozitif
GPU	Grafik İşlem Birimi (Graphics Processing Unit)
IoU	Birleşim Üzerinden Ortalama Kesişim (Intersection Over Union)
KIBT	Konik Işınlı Bilgisayarlı Tomografi
kV	Kilovolt
mA	Miliamper
mAP	Ortalama Kesinlik Değerlerinin Ortalaması (Mean Average Precision)
Mikro BT	Mikro Bilgisayarlı Tomografi
mm	Milimetre
MRG	Manyetik Rezonans Görüntüleme
MS COCO	Microsoft Common Objects in Context
NPD	Nazopalatin Duktus
NPK	Nazopalatin Kanal
PNG	Portable Network Graphics

ROC	Alıcı İşlem Karakteristiğı (Receiver Operating Characteristic)
sn	Saniye
TN	Doğru Negatif
TP	Doğru Pozitif
USG	Ultrasonografi
YOLO	You Only Look Once
YOLOv5	You Only Look Once version 5
YSA	Yapay Sinir Ağı



ŞEKİLLER

Şekil 1.1. Kuru kafa fantomu üzerinde NPK'nın sagittal plandaki kesiti (Von Arx ve Lozanoff, 2017).....	1
Şekil 1.2. Kuru kafa fantom üzerinde insisiv foramen (IF ile gösterilmiştir), sağ ve sol NPK (NPCr ve NPCl ile gösterilmiştir), sağ nazopalatin foramenin (NPCrno ile gösterilmiştir) palatalden görünümü (Von Arx ve Lozanoff, 2017).....	2
Şekil 1.3. Nasopalatin sinirin seyri (Netter, 2022)	3
Şekil 1.4. Nasopalatin arterin seyri (Netter, 2022)	4
Şekil 1.5. Bornstein ve arkadaşlarının koronal planda NPK sınıflandırması (Bornstein ve ark., 2011).....	5
Şekil 1.6. Görürgöz ve Öztaş'ın sagittal planda kullandıkları NPK sınıflandırması (Görürgöz ve Öztaş, 2021).....	6
Şekil 1.7. Fernández-Alonso ve arkadaşlarının aksiyal planda NPK sınıflaması (Fernández-Alonso ve ark., 2014).....	7
Şekil 1.8. Guta-Perka yerleştirilmiş Patent NPD olan bir hastaya ait okluzalden görünüm ve aynı hastaya ait pariapikal radyografi (Von Arx ve Lozanoff, 2017)....	11
Şekil 1.9. Yapay zeka ile alt tekniklerinin ilişkisini temsil eden Venn diyagramı (Khanagar ve ark., 2021).....	18
Şekil 2.1. NPK dallanması olan bir aksiyel kesitte Craniocatch yazılımında NPK etiketlenmesi	27
Şekil 2.2. NPK dallanması olmayan bir aksiyel kesitte Craniocatch yazılımında NPK etiketlenmesi	28
Şekil 2.3. YOLOv5x-seg modeli ile gerçekleştirilen NPK segmentasyonu modelinin diyagramı.....	30
Şekil 2.4. Grup-1 ve Grup-2'ye ait gerçek ve tahmini segmentasyon örnekleri.....	31
Şekil 3.1. Grup-1 için ROC eğrisi.....	37
Şekil 3.2. Grup-2 için ROC eğrisi.....	37

ÇİZELGELER

Çizelge 2.1. Görüntü ve etiket sayılarının dağılımı	29
Çizelge 2.2. İki sınıflı Karışıklık Matrisi (Alan ve Karabatak, 2020).	32
Çizelge 3.1. YOLOv5x-seg modeli için TP, FP ve FN değerleri	35
Çizelge 3.2. YOLOv5x-seg modeli için Duyarlılık, Kesinlik ve F1 Skoru değerleri	35
Çizelge 3.3. YOLOv5x-seg modeli için IoU ve mAP değerleri	36
Çizelge 3.4. NPK dallanma durumunun ilk ve tekrar değerlendirilmelerinin uyum analizi sonuçları	38



1. GİRİŞ

1.1. Nazopalatin Kanalı

1.1.1. Nazopalatin Kanalının Anatomisi


Nazopalatin Kanalı (NPK); maksiller santral keserlerin posteriorunda, orta hatta lokalizasyon gösteren bir anatomik oluşumdur (Sicher ve Dubrul, 1975; Williams ve ark., 1989). Nazal ve oral kavitelereki yumuşak dokuları birbirine bağlamaktadır (Knecht ve ark., 2005; Jacobs ve ark., 2007). Şekil 1.1.'de kuru kafa fantomu üzerinde NPK'nın sagittal plandaki kesiti görülmektedir.



Şekil 1.1. Kuru kafa fantomu üzerinde NPK'nın sagittal plandaki kesiti (Von Arx ve Lozanoff, 2017)

İnsisiv foramen ya da fossa, NPK'nın oral kaviteye açılan huni şeklindeki açıklığını tanımlar (Von Lanz ve Wachsmut, 1985; Langland ve Langlais, 1997; Standring, 2005; Mallya ve Lam, 2019). NPK'nın nazal kaviteye foramina Stensen ya da nazopalatin foramen olarak isimlendirilen mediolateral olarak uzanan iki foramina ile açıldığı belirtilmiştir (Radlanski, Emmerich ve Renz, 2004; Standring, 2005; Jacobs ve ark., 2007; Song ve ark., 2009). Ayrıca foramina Scarpa adlı

anteroposterior olarak konumlanan iki küçük foramina da NPK merkezinde yer alır (Langland ve Langlais, 1997; Von Arx ve Lozanoff, 2017; Mallya ve Lam, 2019). Şekil 1.2.'de kuru kafa fantom üzerinde NPK ve açıklıklığının palatalden görünümü izlenmektedir.




Şekil 1.2 .Kuru kafa fantom üzerinde insisiv foramen (IF ile gösterilmiştir), sağ ve sol NPK (NPCr ve NPCl ile gösterilmiştir), sağ nazopalatin foramenin (NPCrno ile gösterilmiştir) palatalden görünümü (Von Arx ve Lozanoff, 2017)

NPK içerisinde Nazopalatin arter, ven ve sinirleri içeren bir nörovasküler demet bulunur. Hem histolojik hem de radyolojik inceleme yapılan bir çalışmada kemik kanalları ile arter sayısı arasında korelasyon mevcutken, kemik kanalları ile ven ve sinir demetlerinin sayısının ilişkili olmadığı gözlenmiştir. Ayrıca sinir demeti sayısının genellikle 2'den fazla olduğunu belirtilmiştir. Aynı çalışmada; kan damarlarının NPK'ın hem santral hem lateral kanallarında bulunduğu, buna karşın sinir demetlerinin temel olarak santral kanalda veya lateral kanallarının merkezinde olduğunu bildirmişlerdir (Song ve ark., 2009). Ayrıca yapılan başka bir çalışmada NPK'da nörovasküler yapıların yanısıra serömüköz bezlere de rastlanılmıştır (Liang ve ark., 2009).

Maksiller sinir trigeminal sinirin ana dallarından bir tanesidir. Nazopalatin sinir ise maksiller sinirin sphenopalatin dalından ayrılan bir sinirdir. Trigeminal sinir gibi


nazopalatin sinir de duyu lifleri içermektedir. Nazopalatin sinire ait duyu lifleri, septum ve anterior palatinal bölgeyi başka deyişle premaksiller mukoza ile palatal gingivayı innerve ederler. Ayrıca, sempatik ve parasempatik sinir lifler de içermektedir. Bu lifler ile septal ve palatal mukozadaki sekresyonun kontrolünü sağlanmaktadır (Chandra, Rohman ve Walsh, 2008; Fitzpatrick ve Downs, 2022).

Sphenopalatin sinir, pterygopalatin fossa içerisinde bulunan pterigopalatin gangliyonundan geçtikten sonra, sphenopalatin foramen aracılığıyla nazal kaviteye ulaşır. Sphenoid sinüs ostiumunun altından medial olarak ilerleyerek nazal septuma gelir. Buradan NPK'a ulaşana kadar mukoza ile periosteum/perikondrium arasında oblik olarak aşağı ve ileri doğru seyreder. Nazopalatin sinir, NPK ve insisiv forameni geçtikten sonra major palatinal sinir dalları ile birleşir. Bu sayede premaksillanın ikili innervasyonu sağlanır (Chandra, Rohman ve Walsh, 2008; Fitzpatrick ve Downs, 2022). Nasopalatin sinirin seyri Şekil 1.3.'de gösterilmiştir.



Şekil 1.3. Nasopalatin sinirin seyri (Netter, 2022)

Nazopalatin arter, maksiller arterden pterigoapaltin fossa içerisinde kaynağını alan sfenopalatin arterin bir dalıdır ve sfenopalatin foramen aracılığı ile burun boşluğuna girer. Nasopalatin sinir ile beraber septum boyunca oblik şekilde ilerleyerek, desendan palatin arterin terminal dalları ile palatinal bölgenin anteriorunda anastomoz yapmak üzere NPK'a ulaşır ve içinden geçer (Von Arx ve Lozanoff, 2017; Fitzpatrick ve Downs, 2022). Nasopalatin sinirin seyri Şekil 1.4.'de gösterilmiştir.



Şekil 1.4. Nasopalatin arterin seyri (Netter, 2022)

1.1.2. Nazopalatin Kanalı Morfolojisi ve Varyasyonları


Kanalin morfolojisinin karakteristik olarak “V” ya da “Y” şeklinde olduğu belirtilse de (Lake ve ark., 2018), kanalin morfolojisi oldukça fazla ve önemli miktarda değişkenlik (Panjnoush ve ark., 2016; Von Arx ve Lozanoff, 2017) göstermektedir. Literatürde NPK için pek çok sınıflama mevcuttur.

Koronal planda incelendiğinde NPK kanal dallanmasına göre sınıflandırılabilir. Buna örnek olarak Bornstein ve ark.larının sınıflaması sayılabilir. Bu sınıflamaya göre NPK;

A. tek geniş bir kanal,


B. iki dar kanal,

C. üst kısımda dallanmalar içeren Y-şekilli kanal olmak üzere 3 farklı grup şeklinde izlenebilir (Bornstein ve ark., 2011). Sınıflamanın şematize edilmiş hali Şekil 1.5.'de görülmektedir.



Şekil 1.5. Bornstein ve arkadaşlarının koronal planda NPK sınıflandırması (Bornstein ve ark., 2011)

NPK sagittal planda ise, şekilleri üzerinden(huni, kum saati, muz, silindirik gibi) farklı gruplarda incelendiği pek çok sınıflama mevcuttur (Görürgöz ve Öztaş, 2021). Görürgöz ve Öztaş'ın çalışmalarında kullandıkları sagittal plandaki modifiye bir NPK sınıflaması Şekil 1.6.'de görülmektedir.




Şekil 1.6. Görürgöz ve Öztaş'ın sagittal planda kullandıkları NPK sınıflandırması (Görürgöz ve Öztaş, 2021)

Axial planda ise NPK insisiv foramina ve foramina Stenson sayısına göre yapılabilir. Buna Fernandez-Alonso ve ark.larının sınıflaması örnek gösterilebilir. Bu sınıflamaya göre NPK dört farklı grupta incelenebilir:

1. 1 insisiv foramina ve 1 foramina Stenson (1.1),
2. 1 insisiv foramina ve 2-5 foramina Stenson (1.2-5),
3. 2 insisiv foramina ve 2-3 foramina Stenson (2.2-3)

4. 3 insisiv foramina ve 1-3 foramina Stenson (3.1-3) (Fernández-Alonso ve ark., 2014). Bu sınıflamaya ait görüntüler Şekil 1.7.'da görülmektedir.



Şekil 1.7. Fernández-Alonso ve arkadaşlarının aksiyal planda NPK sınıflaması (Fernández-Alonso ve ark., 2014)

Bunlar ve daha pek çok sınıflamalardan da görüleceği üzere NPK değerlendirilirken sadece “V” veya “Y” şeklinde bir kanal olarak tanımlamak yetersiz kalmaktadır, çünkü bu tanımlama sadece belli bir alt grubu yansıtabilmektedir (Friedrich ve ark., 2015).

1.1.3. Nazopalatin Kanalin Klinik Önemi

NPK, morfolojisi ve boyutlarındaki varyasyonlar ile nörovasküler içeriğindeki çeşitlilik dolayısıyla; bulunduğu bölgedeki klinik işlemler açısından önem taşımaktadır (Liang ve ark., 2009). Klinik olarak önem taşıdığı durumlar; lokal anestezi, palatal cerrahi, dental implant cerrahisi, yarık damak gibi konjenital defektler ve bunların onarımı, meziodensler, patent Nasopalatin Duktus (NPD) veya Nazopalatin Kist gibi patolojik oluşumların varlığı, epistaksis olarak sayılabilir (Liang ve ark., 2009; Von Arx ve Lozanoff, 2017; Lake ve ark., 2018; Fitzpatrick ve Downs, 2022). Bu durumlarda ve bunlara ek olarak travmatik lezyonların onarımı

veya palatal ekspansiyon gibi ortodontik tedavi ile ilişkili cerrahilerde; yapılacak operasyonun planlaması NPK'nın topografi ve morfolojisinden etkilenebilmektedir (Iamandoiu, Mureşan ve Rusu, 2022).

Maxillofasiyal cerrahi prosedürlerinde Nazopalatin sinir blokajına sıklıkla ihtiyaç duyulmaktadır (Fitzpatrick ve Downs, 2022). Nazopalatin sinir blokajında, nazopalatin siniri bilateral olarak uyuşurabilmek adına NPK'da anestezi ajan birikimi sağlanmalıdır (Schwartz, 2012).

NPK bölgesinde yapılan implant cerrahisi ile diğer cerrahi prosedürler için anterior maksilladaki ölçümler ve NPK morfolojisi ile boyutlarının belirlenmesi; mevcut kemik miktarının saptanmasının yanı sıra, anatomik oluşumların korunması ve NPK'nın perforasyonu, kanama, duyuşal işlev bozukluğu, implant osseointegrasyonunun engellenmesi gibi komplikasyonların önlenmesi açısından önem taşımaktadır (Jacobs ve ark., 2007; Bornstein ve ark., 2011; Bernades-Mayordomo, Guijarro-Martínez ve Hernández-Alfaro, 2013; Fernández-Alonso ve ark., 2015). Anterior maxilla cerrahisi sırasında NPK içinden ya da yakınından geçen anatomik oluşumlara, cerrahi aletler ile implantlar temas edebilir ve bu durum bahsi geçen komplikasyonların ortaya çıkmasıyla sonuçlanabilir (Rosenquist ve Nyström, 1992; Scher, 1994; Artzi ve ark., 2000; Liang ve ark., 2008; Raghoobar, Den Hartog ve Vissink, 2010; Taschieri ve ark., 2012; De Oliveira-Santos ve ark., 2013; Von Arx ve ark., 2013).

Kompleks restoratif bir prosedür olan anterior dişsiz bölgenin implant ile rehabilitasyonunun yapılabilmesi için titiz ve doğru bir osteotomi planlamasının yapılması bölgenin karmaşık anatomisinden ötürü gereklidir (Mardinger ve ark., 2008). Maksiller keser dişlerin çekimi sonrasında apikolingual yönde alveolar proçesin progresif kemik kaybı meydana gelir ve alveolar kret anatomik yapılara başka bir ifade ile insisiv foramenlere doğru yaklaşır. Bazen insisiv foramenin bu migrasyonu sonrasında, Nazopalatin sinir ve damarlar alveolar kret tepesinde lokalize olabilir. Ayrıca travma, kist, tümör, periodontal hastalık, diş çekimi gibi çeşitli durumlarda; maksiller keser dişlerin kaybının yanı sıra maksillanın kemik yapısı bozulabilir (Mardinger ve ark., 2008; Raghoobar, Den Hartog ve Vissink,

2010). Bunlar sonucunda NPK'nın morfometrisinde deęişim karřımıza çıkmaktadır (Artzi ve ark., 2000; Fukuda ve ark., 2015).

Maksiller anterior bölgede implant uygulamasının, kemik rezorpsiyonu sonrasında genişlemiş insisiv foramen nedeniyle uygun şekilde yapılması da zorlaşmaktadır (Artzi ve ark., 2000). NPK içerisine implant yerleştirilmesi riski, santral keser diş çekimini takiben gelişen labial kemiğin rezorpsiyonu ve dolayısıyla NPK'a komşu kemik miktarının azalması sonrasında artmaktadır (Von Arx ve Lozanoff, 2017). Anterior maksillar bölgede NPK ile yakın ilişki olması, implant uygulamalarında dikkatli bir radyolojik analizi de gerekli kılmaktadır (Bornstein ve ark., 2011).

Restoratif diş prosedürleri esnasında, Nazopalatin sinir ve arter yaralanmaya eğilim gösterirler (Lake ve ark., 2018). Buna rağmen literatürdeki olgu raporlarında; nazal septal cerrahi, maksiller kanin çekimi, insisiv forameninin nörovasküler demetin elektif divizyonu, kret augmentasyonu ile Nazopalatin sinirin posterior lateralizasyonu gibi çeşitli cerrahi prosedürler sonrasında anterior maksillada, az sayıda geçici duyu deęişikliği bildirilse de, kalıcı sensivite deęişikliği olmadığı bildirilmiştir (Von Arx ve Lozanoff, 2017). Sert damak bölgesinin sensivitesinin, nazopalatin sinir kesisinden etkilenmedięi ve major palatin sinirin tüm sert damak mukozasının normal sensivitesini sağlayabilme kapasitesine sahip olduęu sonucuna varılmıştır. Bunun yanısıra, duysal dallar anterior palatinal bölgeye canalis sinosustan gelen kemik kanallar aracılığıyla da taşınabilmektedir (Von Arx ve ark., 2013).


Nazopalatin sinir blokajı yapılırken yarık damak hastalarında klinik işlemler esnasında zorluklar karřımıza çıkabilmektedir. Nazopalatin sinir blokajı sadece incomplet yarık damak vakalarında uygulanabilmektedir. Çünkü complet damak yarıklarında premaksilla deforme bir yapıya sahiptir (Reena, Bandyopadhyay ve Paul, 2016). Ayrıca cerrahi olarak yarık damak gibi müdahale edilecek bölgedeki varyasyonlar ve NPK anatomisindeki farklılıklar, cerrahi prosedür planlaması gerektirir ve cerrah için önem taşımaktadır (Choi ve ark., 2016; Sachdeva, Donkers ve Kim, 2016; Dolci ve ark., 2018).

Orta hatta, iki santral keser diş arasında bulunan, sıklıkla palatal veya alveolar proses içinde konumlu olan sünnümerer dişler meziodens olarak tanımlanır. Daha az sıklıkla nazal tabanın kortikal kemiği veya NPK ile ilişkili olduğu ve radyografide rastlantısal olarak saptanabilir, çünkü semptom veya komplikasyon oluşmadıkça farkedilmeyebileceği bildirilmiştir (Mossaz ve ark., 2014; Aoun ve Nasseh, 2016).

NPK'nın bir parçası ve bir epitel yapısı olan NPD, insanda persiste olabilir ve işlevsizdir (Jacob ve ark., 2000). Obliterasyona ve dejenerasyona uğraması, doğumdan önce veya ilk postnatal yıl içerisinde meydana gelir (Noyes, 1935; Bellairs, 1951; Meyer, 1958). Bazen tek veya çift taraflı olarak, NPD açıklığı erişkinlerde devam edebilir ya da oluşabilir (Roper-Hall ve Dent, 1941; Hill ve Darlow, 1945; Allard, De Vries ve Van Der Kwast, 1982).

Patent NPD klinik olarak çoğunlukla vakaların asemptomatik olduğu (Rodrigues ve ark., 2009); ancak şişlik, rahatsızlık, ağrı gibi çeşitli klinik durumlara da yol açabilen (Von Arx, Schaffner ve Bornstein, 2018) bir antitedir. Öncelikle; insisiv papilla bölgesinde patoloji sık görülmediğinden, NPD klinisyen tarafından intraoral muayene dikkatli yapılmadıkça rahatlıkla saptanamaz (Lundner ve Warunek, 2006). Patent NPD nadiren ağrı, enfeksiyon gibi bulgulara neden olur. Ayrıca; sıvı/havanın bu geçitten geçişi, hastada cızırtılı/ıslık seslerinin oluşması gibi anormal şikayetlerle hekime başvuru olabilir (Von Arx, Schaffner ve Bornstein, 2018). Guta-perka yerleştirilerek radyografi alınması gibi çeşitli tekniklerle incelenebilir (Rawengel, 1923; Lee, Lee ve Lee, 2013). Patent NPD'nin fistül ağzını veya periapikal lezyonu taklit etmesi sonucunda yanlış yorumlanması gereksiz endodontik tedavi yapılmasına neden olabilir (Broome ve Seymour Jr, 1976; Moss, Hellstein ve Johnson, 2000; Suter ve ark., 2011). Bunların yanı sıra; literatürde patent NPD varlığı, NPK kisti gelişimi ile de ilişkilendirilmiştir (Falci ve ark., 2013). Etiyolojik olarak ortodontik palatal ekspansiyon sonrasında (Eppley ve Delfino, 1988; Lundner ve Warunek, 2006; Pithon, 2011) veya santral keser diş çekimini takiben immediat ya da geç yapılan implant cerrahisi sonucunda (Casado ve ark., 2008; Sivoletta ve ark., 2013; Takeshita ve ark., 2013) NPD'un uyarıldığı ve NPK kisti meydana geldiğini bildiren yayınlar mevcuttur. Son olarak; patent NPD'un çekim sonrası oroantral fistül varlığının saptanmasında Valsalva manevrası

yapılırken yanılabilirliği, bu sebeple diagnostik olarak tehlikeli olduğu belirtilmiştir (Leboucq, 1881; Valstar ve Van Den Akker, 2008). Patent NPD vakasının okluzalden görünümü ve Guta-Perka ile alınmış periapikal radyografi Şekil 1.8.'de görülmektedir.



Şekil 1.8. Guta-Perka yerleştirilmiş Patent NPD olan bir hastaya ait okluzalden görünüm ve aynı hastaya ait periapikal radyografi (Von Arx ve Lozanoff, 2017)

İnsisiv Kanal kisti olarak da isimlendirilen NPK kist, çoğu nazopalatin foramen ya da kanalda meydana gelen gelişimsel non-odontojenik bir kisttir. En yaygın non-odontojenik kisttir (Larheim ve Westesson, 2006; El-Naggar, Chan ve Grandis, 2017; Philbert ve Sandhu, 2020). Erkeklerde kadınlara göre biraz daha fazla görülür. Dördüncü ve altıncı dekatlarda daha sıktır (Elliott, Franzese ve Pitman, 2004; Cecchetti ve ark., 2012). NPK'nın çapı 6mm'den fazla olduğunda NPK kistinden şüphelenilmesi gerektiği bildirilmiştir (Elliott, Franzese ve Pitman, 2004; Mccrea, 2014). Klinik olarak anterior maksillada, palatinal bölgede, orta hatta genellikle asemptomatik şişlik olarak izlenir (Mccrea, 2014). Radiküler kistle ayırıcı tanısı, ilişkili olduğu dişin vital olması ile yapılır (El-Naggar, Chan ve Grandis, 2017; Ozcan, 2017; Mallya ve Lam, 2019; Philbert ve Sandhu, 2020).

Radyolojik görüntüleme yöntemleri olarak periapikal, panoramik ve okluzal radyograflar; Konik Işınlı Bilgisayarlı Tomografi (KIBT) kullanılmaktadır (Orhan ve Ünsal, 2021). Ayrıca Manyetik Rezonans Görüntüleme ve Ultrasonografi (USG) ile de görüntülenmesi yapılabilir (Hisatomi ve ark., 2001; Orhan ve Ünsal, 2021). NPK

kistleri palatal flep kullanılarak cerrahi enükleasyon ile tedavi edilir (Cecchetti ve ark., 2012).

Epistaksis burunda aktif kanama olmasıdır ve bu duruma oldukça sık rastlanılır (Viehweg, Roberson ve Hudson, 2006). Sphenopalatin arterin posterior septal dalı, superior labial arterin nazal septal dalı ve anterior etmoidal arterin dalları arasındaki anastomozun olduğu Little alanı, epistaksisin büyük bir çoğunlukla meydana geldiği bölgedir. (Schaitkin, Strauss ve Houck, 1987). Genellikle konservatif tedavi tercih edilse de inatçı kanamalarda cerrahi müdahale yapılır. Cerrahi olarak genellikle sphenopalatin arter ya da maksiller arterin posterior septal dallarına müdahale edilir. Butrymowicz ve ark.ları, epistaksise cerrahi müdahale için sphenopalatin arterin insisiv foramenden koterizasyonu yöntemini tanımlamışlardır. Çalışmalarında, bu yöntemi uyguladıkları hiçbir hastada 24 ay burun kanaması görülmediğini bildirmişlerdir. Septal perforasyon, septal hematoma ve diş ile damak anestezisi bu yöntemin komplikasyonlarıdır (Butrymowicz ve ark., 2016).

1.1.4. Nazopalatin Kanalın Radyolojik Görüntülenmesi

Periapikal ve okluzal radyografi gibi intraoral radyografi, panoramik radyografi gibi ekstraoral radyografi teknikleri, NPK'nın görüntülenmesinde kullanılmaktadır (Mallya ve Lam, 2019).

İnsisiv foramen, intraoral ve panoramik radyografilerde santral keser dişlerin orta ve apikal üçlü bölgesinde genellikle diffüz sınırlı oval radyolusent saha olarak izlenir. Bazen NPK'nın yan duvarları izlenebilir. Bu yan duvarlar, nazal açıklığın tabanından insisiv foramenlere doğru uzanan iki radyopak çizgi olarak seyredilir. Abartılı bir vertikal açı kullanımı, Stensen foramenlerinin görülmesini sağlayabilir (Mallya ve Lam, 2019).

2 boyutlu görüntüleme teknikleri; doğası gereği magnifikasyon, distorsiyon ve süperpozisyon gibi sınırlamalara sahiptir. Bu durum ve bununla beraber 3 boyutlu bir yapının 2 boyutta gösterilmeye çalışılması, yapıların tam doğru bir şekilde

gösterilememesine neden olur (Scarfe ve Farman, 2008). Bukkolingual alveolar kemik genişliği gibi 3 boyutlu yapı özellikleri söz konusu olduğunda konvansiyonel radyografi tekniklerinden bilgi elde edilemez (Tyndall ve Brooks, 2000). Bu da ileri görüntüleme tekniklerinin kullanımını gerektirmektedir.

NPK ve insisiv foramen bir ileri görüntüleme yöntemi olan KIBT ile de görüntülenebilir ve KIBT görüntülerinde bu anatomik yapılar daha iyi yansıtılmaktadır (Mallya ve Lam, 2019). NPK konumu ve boyutu hakkında klinik olarak önemli ve ayrıntılı bilgiler, KIBT sayesinde elde edilebilir (Panjnoush ve ark., 2016).

Ayrıca başka ileri görüntüleme yöntemleri olarak, Bilgisayarlı Tomografi (BT) (Cavalcanti ve ark., 1999; Mraiwa ve ark., 2004; Mardinger ve ark., 2008; Liang ve ark., 2009), MRG (Jacobs ve ark., 2007; Liang ve ark., 2009) ve Mikro Bilgisayarlı Tomografi (Mikro-BT)(Song ve ark., 2009; Fukuda ve ark., 2015) kullanılmıştır. Bunların yanısıra NPK kisti USG yardımıyla da görüntülenebilir (Orhan ve Ünsal, 2021).

1.1.4.1. Konik Işınlı Bilgisayarlı Tomografi

KIBT, konik ışın tekniğini kullanan bir BT türüdür. Maksillofasiyal bölge, KIBT aracılığıyla 3 boyutlu olarak değerlendirilebilmektedir (Mozzo ve ark., 1998). KIBT konik ışın geometrisi ile radyasyon üreten bir X-ışını kaynağı ve tek, düz-panel veya görüntü yoğunlaştırıcı radyasyon dedektöründen oluşur. Döner bir platforma X-ışını kaynağı ve reseptörünün sabitlenmesi ile görüntüleme meydana gelmektedir. Hacimsel bir veri setinde matematiksel olarak yeniden yapılandırılan çoklu, sıralı ve düzlemsel görüntüler, X-ışın kaynağı ve dedektör sayesinde, platform nesne etrafında döndükçe üretilir (Danforth, Dus ve Mah, 2003).

Düşük ışınlama parametreleri gibi özellikleri sayesinde, KIBT yaygınlaşan kullanım alanlarına sahiptir (Aktan ve ark., 2015). Dentoalveoler cerrahi için implant planlaması, 3. molar dişin mandibular kanal ile ilişkisi, maksillofasiyal travmaların

değerlendirilmesi, lezyonların 3 boyutlu incelenmesinde KIBT yaygın olarak kullanılmaktadır. Ayrıca ortodonti, endodonti, periodontoloji, adli diş hekimliği ve kulak burun boğaz alanlarında da sıklıkla KIBT görüntülerine başvurulmaktadır (De Vos, Casselman ve Swennen, 2009; Aktan ve ark., 2015).

Konvansiyonel BT ile kıyaslandığında; X-ışını demetini paralelleştirerek sınırlaması, izotropik vokseller sayesinde görüntünün daha doğru olması, hızlı tarama süresi, radyasyon dozunun daha az olması, maksillofasiyal bölgeye özel görüntüleme modları içermesi, çeşitli artifakt azaltıcı algoritmalar içermesi avantajları olarak sayılabilir. KIBT'nin dezavantajı ise görüntü netliğinin artifaktlar, gürültü ve zayıf doku kontrastı tarafından kötü yönde etkilenmesidir (Venkatesh ve Elluru, 2017).

NPK, mandibular kanal, mental foramen gibi anatomik oluşumlar; KIBT'nin artan kullanımı ve görüntüleme teknolojilerindeki yenilikler sayesinde yakından ve daha doğru bir şekilde incelenebilmektedir (Bornstein ve ark., 2011). Bunun yanı sıra, KIBT yapay zeka alanında da pek çok çalışmada kullanılmaktadır. (Badr ve Jadu, 2022; Mureşanu ve ark., 2022).

1.2. Yapay Zeka

1.2.1. Yapay Zeka'ya Giriş

Zeka, kavram ve nesneler arasında ilişki kurabilme, düşünüp çözüm üretebilme, karar verebilme, yargılama ve sonuç çıkarma yeteneği olarak tanımlanmakta ve adapte olma, anlama, öğrenme, analiz edebilme gibi eylemlerin gerçekleştirilebilmesini sağlamaktadır (Yılmaz, 2020). Yapay zeka ise, veriler aracılığıyla öğrenebilen makinelerin problemleri çözmeleri amaçlanarak geliştirilmiş sistemlerdir (Akst, 2019).

Yapay zeka çalışmalarına Alan Turing ile başlandığı kabul edilebilir. Turing, akıllı makineler üzerine 1947 yılında bir konferans vermiştir. Ayrıca yapay zekanın

en iyi makinelerin yapılması ile değil bilgisayarların programlanması ile araştırılabileceğine karar veren ilk kişi olabileceği belirtilmiştir (Mccarthy, 2007).

Turing, 1950 yılında yazdığı bir makalede “Makineler düşünebilir mi?” problemini cevaplamak adına, bu probleme eşdeğer olarak tasarladığı “Taklit Oyunu”nu, günümüzdeki kavramsallaştırılmış ismi ile “Turing Testi”ni tanımlamıştır. Bu makale ile bir makinenin bir insan gibi düşünüp, zeki olabileceği düşüncesi ilk kez olarak ortaya konmuştur. Aynı zamanda bu makalede; insan-bilgisayar arasındaki farkı, etkileşim sırasında insan fark edemiyor ise bilgisayarın insan kadar akıllı kabul edilmesi gerektiği varsayımında bulunulmuştur (Turing, 1950).

1956’da ise John McCarthy, önemli bir dönüm noktası olan Darmouth Collage’da yapılan bir konferansta “Yapay Zeka” terimini ortaya atmıştır (Moor, 2006). McCarthy, yapay zekayı “Zeki makineler özellikle de zeki bilgisayar programları yapma bilimi ve mühendisliği” olarak tanımlamaktadır (Mccarthy, 2007).

Yapay zeka; insanın öğrenme, karar verme ve problem çözme gibi düşünme becerileriyle alakalı eylemlerin otomasyonu olarak 1978’de Richard Bellman tarafından ifade edilmiştir (Bellman, 1978).

Günümüzde ise; problem çözme, karar verme gibi insana özgü karmaşık bilişsel becerilerini taklit edebilen herhangi bir makine veya teknoloji yapay zekayı ifade eder (Khanagar ve ark., 2021).

Yapay zeka, doğal zekadan belirli özellikleri ile ayrılmaktadır. Yapay zeka, doğal zekanın aksine oluşacak cevap durum ve çevresel faktörlerden etkilenip değişmemektedir. Kendisine öğretildiği ve tutarlı şekilde yanıt verir. Doğal zeka gibi sürekli öğrenme, tecrübe kazanma halinde değildir. Sadece eğitim verileri kadar bilgiye sahiptir. Doğal zeka gibi yeni durumlarda eski tecrübe ve bilgiler yorumlanarak yanıt oluşturamaz. Yapay zekada bilgilerin makinelerde depolanıyor olması sayesinde; bilgilerin raporlanması, belgelenmesi ve aktarımı, doğal zekanın

aksine kolaydır. Aynı zamanda depolanan veriler doğal zeka gibi unutulma riski taşımadığından kalıcı özelliكتedir. Yapay zekanın eğitilme süresi, doğal zekanın eğitilip yetkin bir uzmanın yetiştirilmesine göre çok daha kısadır ve daha az maliyetlidir. Yapay zeka, sadece insan modellemesi sonucunda var olup bilgi edinebilir. Doğal zekadaki gibi yaratıcılık, esinlenme gibi özelliklerden yoksundur. Doğal zekanın aksine durmaksızın aktif ve güncellenebilir bir özellikte değildir. Yapay zeka dar bir bakış açısıyla, sadece algoritmalar aracılığı ile öğrenebilir. Hassas bir gözlem ya da sosyal algılama yapamaz (Pirâm, 2006; NahiyeV, 2012; Shabbir ve Anwer, 2018; Pandl ve ark., 2020; Yılmaz, 2020).

1.2.2. Makine Öğrenimi

Yapay zekanın temel bir alt dalı olan Makine Öğrenimi (Hashimoto ve ark., 2018), Arthur Samuel tarafından “bilgisayarlara açıkça programlanmadan öğrenme yeteneđi veren çalışma alanı” şeklinde ifade edilmiştir (Samuel, 1959). Makine Öğreniminde yüklenen verilerden öğrenilen kalıplar aracılığıyla tahmin edilerek problem çözülmektedir (Hashimoto ve ark., 2018; Khanagar ve ark., 2021). Makine Öğreniminde; görüntülerin tespit edilmesi, öğrenilmesi, kendi kendini düzeltmesi, sınıflama ve alt sınıflama yapması gibi insan zihninin ardışık veriler işleyerek yaptığı işlevleri taklit etmektedir (Sen ve ark., 2020).

Verilerin istatistiksel yapı ve kalıplarını algoritmalar aracılığıyla öğrendiđi ve verileri işleyerek cevaplar üretmesi nedeniyle (Sen ve ark., 2020), veri sayısının artması değerlendirmeyi iyileştirir ve yapay zeka tarafından probleme özel cevapların nasıl üretileceđi öğrenilir (Samuel, 1967). Makine öğreniminin, tıpkı radyologların görüntüleri tekrar inceleyerek öğrenmesi gibi, yapay zekanın fazla sayıda ve yeni veri setleri kullanan bir eğitimle deneyim kazanabilmesine ve öğrenerek gelişebilmesine olanak sağlaması yapay zeka sistemlerini avantajlı kılmaktadır (Kohli ve ark., 2017).

1.2.2.1. Yapay Sinir Ağları

Yapay sinir ağları (YSA), popüler bir Makine Öğrenimi tipi olarak karşımıza çıkar. İnsan nöronunun yapısından ilham alır, matematiksel modeller olan yapay nöronlardan oluşur ve bu nöronlar birleştirilerek bir ağ oluşturulur (Nichols, Herbert Chan ve Baker, 2019; Schwendicke, Samek ve Krois, 2020). YSA'ların eğitilmesi tıpkı insan zekasında olduğu gibi örneklerle olur (Arslan ve İnce, 1993). Özellikle dil veya görüntü gibi karmaşık veri yapılarında Makine Öğreniminden performans anlamında daha başarılıdır (Schwendicke, Samek ve Krois, 2020). YSA'ları tahmin, veri ilişkilendirme, veri filtrelenmesi, veri yorumlama işlemlerinde sıkça kullanılır (Ağyar, 2015).

YSA'ları; örnekler üzerinden bilgi toplayarak genelleme yapıp, daha önce karşılaşılmamış örnekler üzerinde önceki örneklerden elde edilen bilgileri kullanarak karar vererek çalışmalarının yanı sıra; hızlı olması, problemleri çözebilmek için öğrenebilmesi ve genelleyebilmesi, kompleks problemleri yüksek başarı oranı ile basitçe çözebilmesi gibi avantajlara sahiptirler. Bunlara ek olarak işlem elemanlarının herhangi birinde hasar meydana gelmesinin tüm sistemi işlevsiz kılmaması, analiz yeteneğinde ciddi bir düşüşe neden olmaması oldukça önemli bir avantajlarıdır (Ergezer, Dikmen ve Özdemir, 2003; Bozüyük, 2005; Yasav, 2008).

1.2.2.1.1. Derin Öğrenme ve Derin Evrişimli Sinir Ağları

Derin Öğrenme; makine öğreniminin bir alt türü olup görüntü yorumlayan yapay zeka sistemlerin çoğu derin öğrenme alt yapısını kullanır (Neri ve ark., 2019). Derin Öğrenme Makine Öğreniminden farklı olarak; ham verinin kontrast, boyut gibi özelliklerinin tanımlandığı ve bu özelliklerin olup olmasına göre çıkarım yaptığı, ön-işlem sürecine gerek duymaksızın sadece ham veriyi işleyerek tahminde bulunabilmektedir (Suzuki, 2017). YSA'larından daha karmaşık ve zor problemleri çözebilmesi (Brotchie, 2019), daha karmaşık ve büyük görüntüleri işlemesi (Ağyar, 2015) için geliştirilmiştir.

Derin Öğrenme daha önce geliştirilen YSA'larından katman sayısı açısından ayrılmaktadır (Murphy, 2012; Lee ve ark., 2017). Daha çok sayıda gizli katmana sahip yapısı sayesinde, çıktıyı öğrendiği yeni bilgilerle beraber adım adım değiştirebilir bir niteliktedir (Neri, De Souza ve Brady, 2019). YSA'larının daha gelişmiş hali olarak kabul edebileceğimiz Evrişimli (Konvolüsyonlu) Sinir Ağı (ESA), Derin Öğrenme mimarilerinde en temel model olarak karşımıza çıkmaktadır (Srivastava ve ark., 2014). Evrişim (konvolüsyon) özel doğrusal bir işlem türü olan matematiksel bir tekniktir (Lecun, Bengio ve Hinton, 2015; Goodfellow, Bengio ve Courville, 2016) ve bu teknik sayesinde derin öğrenme ağlarını, ağın çoğundaki sinirsel bağlantıları doğal olarak yakalanmasını sağlamak üzere kısıtlar (Marcus, 2018). Şekil 1.9.'da Venn diyagramında yapay zeka ile alt tekniklerinin ilişkisini gösterilmiştir.



Şekil 1.9. Yapay zeka ile alt tekniklerinin ilişkisini temsil eden Venn diyagramı (Khanagar ve ark., 2021).

Derin ESA'ları, derin yani çok katmanlı YSA yapısını oluşturan çoklu katmanlar sayesinde daha büyük verileri işleyebilme kapasitesine sahiptir (Hwang ve ark., 2019). Yine Derin Öğrenme sahip olduğu çok katmanlı YSA yapısı sayesinde, görüntü verisi gibi karmaşık veri yapıları ve görüntünün makroskobik desenler gibi

özellikleri yansıtabilir(Schwendicke, Samek ve Krois, 2020). Bunlar da Derin Öğrenmeyi ve Derin ESA'larını kullanışlı kılmaktadır. Yüklenen verilerin kalite ve miktarı da, Derin Öğrenme başarısını etkilemektedir(Luca ve ark., 2022).

Evrişimli Sinir Ağlarının Eğitilmesi

- Derin Evrişimli Sinir Ağlarının (DESA) eğitiminde birincil olarak katman sayıları belirlenerek bir yapay zeka modeli oluşturulur ve katmanlar sıralanır.

- Filtre boyut ve sayısı gibi başlangıç değişkenleri tanımlanır.

- Eğitim setinden bir görüntü girdi verisi olarak modele aktarılır. Her katmanda veriler işlenerek bir sonraki katmana aktarılır (ileri besleme aşaması).

- Hedeflenen sonuç ile ağdan elde edilen sonucun farkı alınarak belirlenen hata, işlemci elemanlarının bağlantı noktalarının hepsine iletilir. (geri besleme aşaması)

- Eğitim veri kümesindeki her bir görüntü için ileri ve geri besleme aşamaları tekrarlanır (Özkan ve Ülker, 2017).

Transfer Öğrenme

Klasik yapay sistemlerinde her problem için en baştan çözüm üretilir, geçmiş deneyim ve yardımcı verilerden faydalanılmaz. Her problem karşısında sıfırdan eğitim verisi oluşturmak mümkün olmadığından, klasik makine öğrenimi metodları gerçek hayatta karşılaşılan problemler karşısında işlevsiz kalmaktadır. Transfer öğrenmede, benzer problemler için kullanılan eğitim modellerinin yeniden düzenlenip geliştirilmesi, söz konusudur. Bu sayede DESA eğitiminin en büyük problemi olan veri setinin azlığı problemi giderilmiş olur. Bunun için örnek model olarak tasarlanmış AlexNet, VGGNet, GoogLeNet, ResNet gibi DESA mimarileri mevcuttur (Koçer, 2012; Başaran, 2020; Tur, 2021).

Derin Öğrenme Kütüphaneleri

Derin Öğrenme için oluşturulmuş hazır kütüphaneler, Derin Öğrenme mimarilerinin hızlıca geliştirilebilmede en büyük rol oynayan etmenlerdendir. Her biri farklı özelliklere sahiptir ve derin öğrenme çalışmalarını pratikleştirip kolaylaştırma işlevini üstlenirler. Bu sayede derin öğrenme ağları geliştirilirken verimlilik arttırılmış olur. Bu kütüphaneler Java, Python, C++ gibi çeşitli programlama dillerinde oluşturulmuştur. Bu kütüphanelere örnek olarak Caffe, Tensorflow, Torch, Keras adlı kütüphaneler sayılabilir (Shi ve ark., 2016; Gündüz ve Cedimoğlu, 2019; Uzun, 2020). Ayrıca Darknet ve Pytorch da bu kütüphanelere örnektir (Shin ve Kim, 2022).

Derin Öğrenmede Görüntü Segmentasyonu

Yapay zekada görüntü analizi için üç farklı yöntem mevcuttur (Minaee ve ark., 2021):

1.Sınıflandırma: Görüntüdeki bir ögenin hangi sınıfa ait olduğunun tahmin edilmesidir (Chollet, 2017; Yaji, Prasad ve Pai, 2019).

2.Nesne Algılama: Görüntüdeki nesnelerin tespit edilmesi ve bir dikdörtgen içine alınmasıdır (Redmon ve Farhadi, 2017; Yaji, Prasad ve Pai, 2019)

3.Segmentasyon: Görüntüdeki bir yapının, diğer yapılardan ayrılması ve sınırlarıyla beraber hangi nesnenin parçası olduğunu belirtmektir. Nesne algılama ve sınıflama bu yöntemden köken almaktadır (Chen ve ark., 2017; Yaji, Prasad ve Pai, 2019).

İki farklı segmentasyon çeşidi mevcuttur:

Birey (Instance) segmentasyon: Aynı türe ait her bir farklı bireye ayrı bir sınıf etiketinin tayin edildiği segmentasyon türüdür.

Semantatik Segmentasyon: Belirli bir nesne türüne ait her ayrı bireye aynı sınıf etiketinin tayin edildiği segmentasyon türüdür (Garcia-Garcia ve ark., 2017).

1.2.2.1.1.1. YOLO (You Only Look Once) ve YOLOv5 (You Only Look Once-version 5)

ESA yapısına sahip olan YOLO (You Only Look Once) oldukça hızlı bir nesne tanıma mimarisi olarak karşımıza çıkmaktadır. YOLO'nun açılımı Türkçede "Sadece bir kez bakarsın" anlamına gelmektedir ve adından da anlaşılacağı üzere algoritma oldukça hızlıdır ve amacı tek seferde nesneyi tespit edebilmektir (Redmon ve ark., 2016). Ayrıca YOLO hızlı olmasının yanı sıra küçük bir yapıya sahip bir mimaridir. Görüntünün sadece sinir ağına aktarılması nihai nesne algılama sonucunun elde edilmesi için yeterli olması, bu mimariyi hızlı kılmaktadır. Ayrıca güçlü bir genelleme yeteneğine sahiptir (Jiang ve ark., 2022).

YOLOv5'te, önceki dört versiyondan farklı olarak ana kütüphane olarak DarkNet yerine PyTorch ve ana yazılım dili olarak C yerine Python kullanılmaktadır (Redmon ve Farhadi, 2018; Jocher ve ark., 2021). YOLOv5'in esas avantajı Python kullanılmasından ileri gelmekte ve PyTorch kullanılması ise daha hızlı eğitimin yapılabilmesine zemin hazırlamaktadır (Jocher ve ark., 2021). YOLOv5'in son resmi güncellemesinde v.7.0 yayınlanmıştır. Bu güncellemede transfer öğrenme tekniği kullanılarak Microsoft Common Objects in Context (MS COCO) veri kümesi ile ön eğitim uygulanmış segmentasyon modelleri kullanıma sunulmuştur (Jocher ve ark., 2022).

1.2.3. Yapay Zekanın Diş Hekimliği ve Ağız, Diş ve Çene Radyolojisinde Kullanım Alanları

Günümüz diş hekimliğinin birçok alanında yapay zeka sistemleri oldukça rağbet görmektedir (Khanna, 2010; Khanagar ve ark., 2021). Tanıda ikincil görüş sağlayan bilgisayar destekli tanı sistemlerine de derin öğrenme sistemleri entegre edilmeye başlanmıştır (Türk, 2021). Ayrıca yapay zeka tabanlı sanal asistanlar

randevuların düzenlenmesi, evrak ve sigorta yönetimi, hastanın mevcut allerjilerinin hekime hatılatılması gibi pek çok görevi üstlenmektedir(Khanna ve Dhaimade, 2017). Yapay zeka teknolojisi sayesinde, insan kaynaklı hatalar minimuma iner ve zaman ile maaliyetten tasarruf sağlanır (Khanna, 2010; Khanagar ve ark., 2021).

Ağız, Diş ve Çene Radyolojisinde periapikal radyografi, bite-wing radyografi, panoramik radyografi, KIBT, BT, USG görüntüleri ve ağız içi fotoğrafları kullanılarak pek çok araştırma yapılmıştır. Yapay zeka sistemleri; diş tanımlama-sınıflandırması, diş eksikliği tespiti, diş morfolojisi tespiti, ekstra kök ve sürnümerer diş tespiti, vertikal kök kırığı saptanması, üçüncü molar diş tespiti, diş çürüklerinin saptanması, periapikal radyolusensi ve lezyon tespiti, periodontal kemik kaybı teşhisi, anatomik yapıların incelenmesi, osteoporoz gibi hastalıkların saptanması, çene kist ve tümör teşhisi, temporomandibular eklem düzensizliği tespiti, oral mukoza patolojilerinin saptanması ve ağız kokusu teşhisi gibi pek çok durumda kullanılmaktadır (Sağlam, 2021; Türk, 2021).

Bu bilgiler ışığında; NPK morfoloji ve varyasyonlarının, basit bir ifade ile dallanma durumunun, KIBT ile tespit edilmesi gerektiği ve bu tespit etme aşamasında doğabilecek değerlendirme zorluklarının aşılması için yapay zekanın kullanılıp kullanılamayacağının değerlendirilmesi gerekmektedir. Bildiğimiz kadarıyla, literatürde NPK segmentasyonunu ve dallanma varlığının tespitini yapay zeka kullanarak inceleyen herhangi bir çalışma bulunmamaktadır.

İmaj temelli tanıda otomatik lezyon saptama, segmentasyon ve sınıflandırma araçları makine öğreniminin temel üstünlüklerini oluşturur. Ayrıca ESA'ları hekimlere benzer şekilde görüntülerdeki hastalığın varlığı veya yokluğu durumuna göre sınıflandırabilir. Yapay zekanın dar bir görev odağının olması, hastaları bir bütün olarak değerlendirme yeteneğine sahip olmaması, büyük miktarda eğitim verisine ihtiyaç duyması, yanlış çıkarımlara varabilmesi, daha iyi donanım gereksinimlerine ihtiyaç duyması ve bunun ulaşılabilirliği azaltması zayıf yönleri olarak sayılabilir (Martín Noguerol ve ark., 2019).

Bu Tez çalışmasının amacı KIBT görüntülerinde NPK'nın segmente edilmesi ve dallanma durumunun değerlendirilmesi açısından gözlemci ile yapay zekayı karşılaştırmak olup; sıfır hipotezi ise "NPK segmentasyonu ve dallanmasının tespitinde KIBT görüntüleri üzerinde yapay zekanın yapacağı değerlendirme ile gözlemcinin yapacağı değerlendirmenin tutarlı olacağı"dır.

NPK varyasyondan oldukça zengin bir anatomik oluşumdur(Panjnoush ve ark., 2016; Von Arx ve Lozanoff, 2017) ve bu oluşumun bulunduğu bölgede gerçekleştirilen klinik işlemler açısından önemli bir yapı olduğu bilinmektedir(Liang ve ark., 2009). Bu noktada NPK'nın dallanma durumunun bilinmesi oldukça önem taşıdığı için NPK ve NPK'nın dallanma durumu üzerine çalışıldı. NPK gibi kanal yapılarının KIBT ile etkin bir şekilde gözlenebildiği literatürde bildirildiği için(Bornstein ve ark., 2011) çalışmada bu görüntüleme modalitesi kullanıldı.

Yapay zeka sistemleri önemli bir geliştirilebilme potansiyeline sahiptir (Demirhan, Kılıç ve İnan, 2010; Martín Noguerol ve ark., 2019). Deneyimi az hekimler için önemli bir tanı destek aracı olabilir (Hurt, Kligerman ve Hsiao, 2020). Ayrıca yapay zeka modellerinin, genelleştirilebilirliği ile güvenilirliğinin doğrulanması (Steyerberg, 2010) ve klinik uygulamada kullanılabilmesi için (Mureşanu ve ark., 2022) geliştirilmesi gerektiği söylenebilir. Bu sebepler göz önünde bulundurularak bu tez çalışmasında yapay zeka teknolojilerinden faydalandı. Literatürde YOLOv5 modifikasyonları ile segmentasyon çalışılmış ve YOLOv5'in segmentasyon için potansiyeli olduğu bildirilmiştir (Wang, Li ve Zheng, 2022). Literatürde, yeni resmi güncelleme ile gelen segmentasyon özelliği ile ilgili herhangi bir araştırma bildiğimiz kadarı ile bulunmamaktadır. Bu noktada YOLOv5 modelinin segmentasyon performansının değerlendirilmesi oldukça önem taşımakta ve gerekmekte olduğu göz önünde bulundurularak bu çalışmada YOLOv5'in segmentasyon modellerinden biri olan YOLOv5x-seg kullanıldı. İki boyutlu(2B) YSA kullanıldığında, anatomik yapının baskın olarak bulunduğu yöneline dik plan üzerinden eğitim setlerinin oluşturulması Minemima ve arkadaşları tarafından yaptıkları çalışmada önerilmiştir. Ayrıca 3 boyutlu YSA sistemlerinin segmentasyon için yeterince geliştirilemediğinin altı çizilmiştir. Bunun yerine tek planda değerlendirilerek 2B veya birden fazla planda ayrı ayrı değerlendirilerek arttırılmış

2B YSA sistemleri iyi performans göstermekte olduđu belirtilmiřtir (Minnema ve ark., 2021). Bu aıdan bakıldığında 2B YSA sistemlerin kolay uygulanabilir olduđu sonucuna varılabilir. 2B yntemler aısından da yksek bařarı ve hıza sahip algoritmalar gerekli olduđu sylenebilir. Bunlar gznnde bulundurularak 2 boyutlu, aksiyel plandaki veri setleri oluřturulmuřtur.



2. GEREÇ VE YÖNTEM

2.1. Veri Setlerinin Oluşturulması

2.1.1. Görüntülerin Seçilmesi

Bu tez çalışmasında, Helsinki Deklarasyonuna uyuldu ve Ankara Üniversitesi Diş Hekimliği Fakültesi Klinik Araştırmalar Etik Kurulu'ndan Etik Kurul 36290600 sayılı, 18/03 karar no'lu değerlendirme ile onay alındı (Ek 1). Çalışma materyalini oluşturan KIBT görüntülerinin elde edildiği hastaların Oral Diagnoz kliniğine ilk başvurularında, radyolojik görüntülerinin araştırma için kullanılması konusunda yazılı onamları alınmaktadır. (Ek 2)

Çalışma kapsamında, Ankara Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi A.D.'da bulunan, Planmeca Promax3d Max Pro Face model KIBT cihazı ile Aralık 2019-Mart 2022 yılları arasında çekilmiş görüntüler retrospektif olarak tarandı. Görüntü parametreleri; görüntüleme alanı (FOV) 50 x 55, 100 x 55, 100 x 90, 130 x 55 veya 130 x 90 mm, 96 kV, 8-10 mA, 12 sn, voksel boyutu 0,2 µm idi.

Yapılan G-Power analizinde testin gücü 0,94, efekt büyüklüğü 0,5 olacak şekilde; ESA performansının eğitim örneklem büyüklüğüne bağlı olduğu (Samala ve ark., 2019) göz önünde bulundurularak hesaplandı, örneklem büyüklüğü 200 olarak bulundu. KIBT görüntülerinde aşağıda belirtilen dahil etme ve hariç tutma kriterlerine göre tarama işlemi gerçekleştirildi.

Görüntülerin Dahil Edilme Kriterleri

- Cinsiyet farketmeksizin, herhangi bir sebepten KIBT görüntüsü alınmış, NPK bölgesi net bir şekilde izlenebilen hastaların görüntüleri

- 18 yaş ve üstü hastaların KIBT görüntüleri

Görüntülerin Dahil Edilmeme Kriterleri

- NPK yapısını veya kortikal sınırlarını etkileyen bir herhangi bir patolojiye veya sistemik hastalığa sahip hastaların görüntüleri
- NPK seyrini etkileyen cerrahi işlem skarı veya fraktürü bulunan hastaların görüntüleri
- NPK kortikal sınırlarını ihlal eden gömülü diş varlığı olan hastaların görüntüleri
- NPK’da kanalın tam olarak seyredilemediği hastalara ait görüntüler
- NPK’da septanın seyrinin anlaşılamayacak kadar ince olduğu hastalara ait görüntüler
- Görüntülerin okunmasını engelleyecek artefakt varlığı

Belirtilen kriterler göz önünde bulundurularak, NPK’da dallanma olan 100 adet KIBT ve dallanma olmayan 100 adet KIBT görüntüsü olmak üzere, toplamda 200 KIBT görüntüsü seçildi.


2.1.2. Kesitlerin Hazırlanması

Seçilen 200 KIBT görüntüsü Digital Imaging and Communication in Medicine (DICOM) dosyası şeklinde kaydedildi. Kaydedilen DICOM dosyalarının aksiyel kesit çerçeve görüntüleri ITK-SNAP (Amerika Birleşik Devletleri) adlı açık kaynak kodlu bir yazılım ile Portable Network Graphics (PNG) formatında dışarı aktarıldı. Dışa aktarılan aksiyel görüntülerden tüm sınırları kortikal kemik ile çevrili NPK


görüntüsü içermeyen kesitler çıkarıldı. Toplamda 7879 adet aksiyel kesit çerçeve görüntüsü CranioCatch yazılımının (Eskişehir, Türkiye) 2 boyutlu Etiketleme Modülüne yüklendi.

2.2. Görüntülerin Değerlendirilmesi ve Etiketlenmesi

Elde edilen aksiyel kesitler; görüntü standardizasyonu amacıyla sabit bir piksel boyutunda (1024 x 1024 piksel) ve kare şeklinde (Kaheel, Hussein ve Chehab, 2021) yeniden boyutlandırıldı. Kesitlerdeki NPK sınırları 4 yıllık deneyime sahip bir Ağız, Diş ve Çene Radyolojisi araştırma görevlisi tarafından aynı şartlarda CranioCatch (Eskişehir, Türkiye) yazılımı kullanılarak serbest çizim tekniği başka bir ifade ile poligon yöntemi ile etiketlendi. Bu sayede NPK'a ait alanlar işaretlendi ve tanımlandı. Ayrıca her bir NPK'daki total dallanma varlığı ya da yokluğu durumu bir excel dosyasına kaydedildi. Ancak etiketleme işlemi sırasında kanalın total dallanma durumundan bağımsız olarak kesitlerdeki dallanma varlığı ya da yokluğu durumuna göre etiketlendi. Aksiyel planda NPK'ın kemik septa ile tamamen ayrılması durumu dallanmanın var olduğu durum olarak kabul edildi (Torres ve ark., 2016). Şekil 2.1.'de NPK dallanması olan bir aksiyel kesitte, Şekil 2.2.'de ise NPK dallanması olmayan bir aksiyel kesitte Craniocatch yazılımında NPK etiketlenmesi gösterilmiştir.



Şekil 2.1. NPK dallanması olan bir aksiyel kesitte Craniocatch yazılımında NPK etiketlenmesi



Şekil 2.2. NPK dallanması olmayan bir aksiyel kesitte Craniocatch yazılımında NPK etiketlenmesi

2.3. Yapay Zeka Modeli ve Eğitilmesi

Bu tez çalışması, PyTorch kütüphanesi ile Python açık kaynaklı kodlama dili kullanan, transfer öğrenme tekniği kullanılarak MS COCO ile ön eğitimden geçirilmiş YOLOv5 mimarisinin v.7.0. versiyonunun modellerinden biri olan YOLOv5x-seg modeli (Jocher ve ark., 2022) ile transfer öğrenme teknikleri kullanılarak yapıldı.

Modellerin eğitimi Ubuntu 18.04.5 LTS (GNU/Linux 4.15.0-136-generic x86_64) işletim sistemine, 2 adet Intel(R) Xeon(R) Gold 5218 CPU @ 2.30 işlemciye, 479GB PERC H330 Adp sürücüyeye, 256 GB Memory RAM'e, 2 adet NVIDIA Tesla V100 16Gb Pcie Gpu ekran kartına sahip bir bilgisayarda gerçekleştirildi.

200 KIBT görüntüsünden elde edilen 7879 aksiyel kesit; NPK'da dallanma var olup olmasına göre iki ayrı gruba ayrıldı. Dallanmanın var olduğu grup (Grup-1), Dallanmanın olmadığı grup (Grup-2) şeklinde iki ayrı grup olarak eğitildi. Dallanmanın var olduğu grupta 1921 görüntü, dallanmanın yok olduğu grupta 5958 görüntü mevcuttu. Çalışma için üç ayrı veri seti oluşturuldu; eğitim veri seti modelin eğitilmesi için, doğrulama veri seti eğitim sürecinde modelin oluşturulup parametrelerin ayarlanması için, test veri seti ise eğitim ve doğrulama setleri aracılığı ile eğitilmiş modelin test edilebilmesi için (Aslan, 2021) kullanıldı. Eğitim veri seti


tüm görüntülerin % 80'ini oluşturan 160 KIBT görüntüsünden, doğrulama veri seti tüm görüntülerin % 10'unu oluşturan 20 KIBT görüntüsünden ve test veri seti tüm görüntülerin % 10'unu oluşturan 20 KIBT görüntüsünden oluşmaktaydı. Görüntü ve etiket sayılarının dağılımı Tablo 2.1.'de gösterilmiştir.

Çizelge 2.1. Görüntü ve etiket sayılarının dağılımı


	Görüntü Sayısı	Etiket Sayısı
Dallanma var olan grup (Grup-1)	1921	4362
Grup-1 eğitim veri seti	1537	3496
Grup-1 doğrulama veri seti	192	434
Grup-1 test veri seti	192	432
Dallanma yok olan grup (Grup-2)	5958	5965
Grup-2 eğitim veri seti	4766	4773
Grup-2 doğrulama veri seti	596	597
Grup-2 test veri seti	595	595

Veri yetersizliği ESA'ları için oldukça önemli bir sorun teşkil etmektedir. Bunu engelleyebilmek için veri arttırma (augmentation) uygulanmaktadır (Ergün ve Kılıç, 2021). Veri arttırma, çeşitli yöntemlerle veri eklenerek kullanılacak veri sayısının artmasının sağlanmasıdır (Purnama ve ark., 2019). Derin öğrenmedeki başarının veri arttırma sayesinde arttığı literatürde gösterilmiştir (Lopez ve ark., 2017). Bu çalışmada, görüntüler yukarı, aşağı, sağa ve sola çevrilmek suretiyle (flip up, flip down, flip right, flip left) veri arttırımı işlemi gerçekleştirilmiştir.

YOLOv5x-seg modeli ile 800 epoch (eğitim turu) yapılarak eğitim gerçekleştirildi. Her iki grupta da öğrenme hızı (learning rate) ise 0,001'di. Şekil 2.3.'de YOLOv5x-seg modeli ile gerçekleştirilen NPK segmentasyonu modelinin diyagramı, Şekil 2.4.'de ise sırası ile Grup-1 ve Grup-2'ye ait gerçek ve tahmini segmentasyon örnekleri gösterilmiştir.



Şekil 2.3. YOLOv5x-seg modeli ile gerçekleştirilen NPK segmentasyonu modelinin diyagramı



Şekil 2.4. Grup-1 ve Grup-2’ye ait gerçek ve tahmini segmentasyon örnekleri

2.4. Yapay Zekanın Performansının Değerlendirilmesi

İstatistiksel bir araç olan Karışıklık Matrisi, başka bir adıyla Hata Matrisi, eşleştirilmiş gözlem sonuçlarının analizinde kullanılır (Lopez ve ark., 2017). Bu tez çalışmasında, Karışıklık Matrisi kullanılarak, tahmin ve gerçek değerler birbirleriyle karşılaştırılmak suretiyle yapay zekanın performansı değerlendirildi (Deng ve ark., 2016). Ayrıca Birleşim üzerinden ortalama kesişim (IoU, Intersection over Union), Ortalama kesinlik değerlerinin ortalaması (mAP, Mean Average Precision) Alıcı işlem karakteristiği (ROC, Receiver Operating Characteristic) ve ROC eğrisinin altında kalan alan (AUC, Area Under Curve) da hesaplandı.

2.5. Performans Değerlendirme Metrikleri

Sınıflandırma için kullanılan modellerin performanslarının değerlendirilmesinde kullanılan değerlendirme metrikleri genel olarak Karışıklık Matrisi adlı tablodan kaynaklanmaktadır (Japkowicz, 2011; Han, Kamber ve Pei, 2012). Matrisin satırları gerçek değerleri, sütunları ise tahmin edilen değerleri göstermektedir (Alan ve Karabatak, 2020). İki sınıflı bir Karışıklık Matrisi Tablo 2.2.'de gösterilmektedir.

Çizelge 2.2. İki sınıflı Karışıklık Matrisi (Alan ve Karabatak, 2020).

		Tahmin Edilen Değer	
		Pozitif	Negatif
		Pozitif	Negatif
Gerçek Değer	Pozitif	TP(Gerçek Pozitif)	FN(Yanlış Negatif)
	Negatif	FP(Yanlış Pozitif)	TN(Gerçek Negatif)

Bu çalışmada yapay zeka modelinin performansının değerlendirilmesinde kullanılan matrisler şöyledir:

Gerçek Pozitif (TP): NPK doğru bulundu ve dallanma durumu ile sayısı doğru sınıflandırıldı.

Yanlış Negatif (FN): NPK bulunamadı ve dallanma durumu ile sayısı sınıflandırılmadı.

Yanlış Pozitif (FP): NPK bulundu ancak dallanma durumu yanlış sınıflandırıldı ve/veya fazla dallanma bulundu.

TP, FN, FP duyarlılık ve kesinlik oranlarının hesaplanabilmesi için yapılan ön hesaplamalardır (Lee, Han, ve ark., 2020).

Duyarlılık (Sensitivity, Recall): Doğru pozitif ve doğru negatif değerlerin pozitiflik derecesini ifade eder. $TP / (TP + FN)$ olarak formülize edilir (Lee, Han, ve ark., 2020).

Kesinlik (Precision): Pozitif olarak tahmin edilmiş verilerin doğruluk oranını ifade eder. $TP / (TP + FP)$ olarak formülize edilir (Lee, Han, ve ark., 2020).

F1 skoru: Kesinlik ve duyarlılık oranlarının harmonik ortalamasının alınması ile elde edilen değerdir. Bir segmentasyon metriği olup, gerçek ve tahmini değerlerinin çakışan piksellerini yorumlar (Lee, Han, ve ark., 2020). Test aşamasındaki modelin etkinliği, F1 skorunun yüksek olmasına bağlıdır (Yu ve Zhang, 2021). $2TP / (2TP + FP + FN)$ olarak formülize edilir (Lee, Han, ve ark., 2020).

Kesinlik, duyarlılık, F1 skoru segmentasyon performansını ölçmek için kullanılabilmektedir (Lee, Gharaibeh, ve ark., 2020).

IoU (Birleşim üzerinden ortalama kesişim): Tahmin edilen ve gerçek değerlerin kesişiminin toplam birleşimine oranlanması ile elde edilir. Çakışma bölgesi büyüdükçe IoU değeri 1'e yaklaşır (Lee, Han, ve ark., 2020). Genellikle IoU değeri 0.5'e eşit ve büyük olduğunda doğru tahmin yapıldığı başka bir ifade ile TP olduğu varsayımı yapılır (Başaran ve Cagil, 2022). Bu çalışmada eşik IoU değeri 0.5 olarak kabul edildi. Bu 0.5'in altındaki değerler başarısız kabul edildi (Yüce, 2022). IoU: $TP / (TP + FN + FP)$ olarak formülize edilir (Lee, Han, ve ark., 2020).

mAP (Ortalama kesinlik değerlerinin ortalaması): Her sınıfa ait ortalama kesinliğin (AP, average precision) ortalaması ile elde edilen değerdir. Nesne algılayabilen modellerde doğruluğun saptanmasını sağlar (Guo, Qian ve Shi, 2021). 0 ile 1 arasında değişen bir değer elde edilir ve sonucun 1'e daha yakın olması istenir (Ucuzal, 2020).

ROC (Alıcı işlem karakteristiği): Duyarlılığın kesinliğe oranının alınması ile elde edilir (Sevli, 2019). Böylece bu iki kavram arasındaki denge değerlendirilmiş (Sevli, 2019) ve testin ayırt edebilme gücü tespit edilmiş (Dirican, 2014) olunur. Bunun yanısıra test etkinliklerinin ve gözlemcilerin tanı etkinliklerinin karşılaştırılmasında da kullanılmaktadır (Dirican, 2014).

AUC (ROC eğrisinin altında kalan alan): ROC eğrisinin altında kalanın hesaplanması ile bulunur (Sevli, 2019). Bu değerin 1'e yakın olması beklenir (Ozenne, Subtil ve Maucort-Boulch, 2015; Cook, 2017). Çünkü bu değerin yüksekliği tahmin doğruluğunu ifade eder (Tomak ve Yüksel, 2009).

2.6. Gözlemci İçi Güvenilirlik

Gözlemci içi güvenilirlik için 2 hafta sonra görüntülerin % 20'si (Aydoğmuş Erik, Erik ve Yıldırım, 2019a, 2019b; Mashyakhy ve Abu-Melha, 2021) dallanma varlığı ya da yokluğu durumu açısından tekrar sınıflandırıldı.

Verilerin analizi SPSS 26.0 programı ile yapılmış ve %95 güven düzeyi ile çalışılmıştır. Kategorik (nitel) değişkenler için frekans (n) ve yüzde (%) istatistikleri verilmiştir. Çalışmada test tekniklerinden Ki-Kare testi kullanılmış, dallanma durumları arasındaki uyumun belirlenmesinde Kappa, Kendall Tau (b), Intraclass korelasyon ilişki katsayıları hesaplanmıştır. Kappa katsayısı için sınıflandırma şu şekildedir; “< 0 Hiç uyuşma yok” , “0.0-0.20 Önemsiz uyuşma olması” , “0.21-0.40 Orta derecede uyuşma olması” , “0.41-0.60 Ekseriyetle uyuşma olması” , “0.61-0.80 Önemli derecede uyuşma olması” , “0.81-1.00 Neredeyse mükemmel uyuşma olması” (Landis ve Koch, 1977). Korelasyon katsayısı için sınıflandırma şu şekildedir; “ $0 \leq r \leq 0,25$ çok zayıf”, “ $0,26 \leq r \leq 0,49$ zayıf”, “ $0,50 \leq r \leq 0,69$ orta”, “ $0,70 \leq r \leq 0,89$ güçlü”, “ $0,90 \leq r \leq 1$ çok güçlü” (Akgül ve Çevik, 2003). Ki-Kare testi; kategorik değişkenler arasındaki ilişkinin belirlenmesinde kullanılan test tekniğidir. Kappa ve Kendall Tau gruplu düzey değişkenlerinin ilişkisinin şiddetinin betimlenmesinde kullanılır.

3. BULGULAR

Bu tez çalışmasında YOLOv5x-seg model derin öğrenme algoritmasının NPK ve kanalın dallanma durumunun tespitindeki performansı incelendi. Modelin başarısı Karışıklık Matrisi kullanılarak değerlendirildi.

YOLOv5x-seg modelinin NPK tespiti ve sınıflandırılması için TP, FP ve FN değerleri Tablo 3.1.'de gösterilmiştir.

Çizelge 3.1. YOLOv5x-seg modeli için TP, FP ve FN değerleri

	Grup-1	Grup-2
TP (Doğru bulunan)	424	796
FP (Yanlış bulunan)	2	2
FN (Bulunamayan)	14	14

YOLOv5x-seg modelinin NPK tespiti ve sınıflandırılması için duyarlılık, kesinlik ve F1 skoru değerleri Tablo 3.2.'de gösterilmiştir. Duyarlılık değerlerine bakıldığında her iki grup için pozitif olarak tahmin edilmesi gereken değerlerin pozitif bulunma oranının, Kesinlik değerlerine bakıldığında ise her iki grup için de pozitif tahminlerin gerçekten pozitif olma oranının yüksek olduğu anlaşılmaktadır (Japkowicz, 2011). F1 skorunun sırasıyla Grup-1 için 0.9815 olarak; Grup-2 için ise 0.9900 olarak bulunması test aşamasında modelin etkin bir şekilde çalıştığını gösterir.

Çizelge 3.2. YOLOv5x-seg modeli için Duyarlılık, Kesinlik ve F1 Skoru değerleri


	Grup-1	Grup-2
Duyarlılık	0.9680	0.9827
Kesinlik	0.9953	0.9975
F1 Skoru	0.9815	0.9900

YOLOv5x-seg modelinin NPK tespiti ve sınıflandırılması için ortalama IoU ve mAP (IoU değeri eşik değeri olan 0.5 iken) değerleri Tablo 3.3.'de gösterilmiştir. Ortalama IoU, değerlerinin sırasıyla Grup-1 için 0.9636; Grup-2 için ise 0.9803 olarak bulunmuş olması tahmini ve gerçek segmente alanlarının birbiri ile yüksek oranda örtüştüğünü ifade etmektedir. mAP değerleri sırasıyla Grup-1 için 0.7930; Grup-2 için ise 0.9637 olarak bulunmuştur. mAP değerinin Grup-1'de düşük olması dallanma varlığında NPK'nın tespitinin güçleştiğini göstermektedir.


Çizelge 3.3. YOLOv5x-seg modeli için IoU ve mAP değerleri

	Grup-1	Grup-2
IoU	0.9636	0.9803
mAP	0.7930	0.9637

YOLOv5x-seg modelinin NPK tespiti ve sınıflandırılması AUC değerleri Grup-1 için 0.8841, Grup-2 için 0.9510 bulunmuştur. Grup-1 için ROC eğrisi Şekil 3.1.'de, Grup-2 için ROC eğrisi Şekil 3.2.'de gösterilmiştir. Grup-1 için ROC eğrisinin 1'e çok yakın olmaması ve AUC değerinin Grup-2'nin değerine göre daha düşük olması NPK'nın dallanma varlığında NPK tahmin doğruluğunun ve testin ayırt etme gücünün NPK'da dallanma olmayan duruma göre daha düşük olduğu anlamına gelmektedir.



Şekil 3.1. Grup-1 için ROC eğrisi



Şekil 3.2. Grup-2 için ROC eğrisi

Gözlemci içi güvenilirliğe bakıldığında, örneklerin değerlendirilen ilk dallanma durumu ile tekrar dallanma durumu arasında istatistiksel anlamlı ilişki bulunmaktadır ($p=0,000<0,05$). İlk ve tekrar dallanma durumu arasındaki uyum Kappa (0,950) katsayısı, Kendall Tau (0,951) ve Intraclass (0,951) korelasyon

katsayılarına göre çok yüksektir. Dallanma durumu gözlemleri arasında mükemmel uyum bulunmaktadır.

Çizelge 3.4. NPK dallanma durumunun ilk ve tekrar değerlendirilmelerinin uyum analizi sonuçları

		İstatistik
Test	Ki-Kare	32,481
	p	0,000
Uyum katsayıları	Kappa	0,950
	Kendall Tau	0,951
	Intraclass	0,951

4. TARTIŞMA

NPK maksilla anteriorda lokalize bir anatomik oluşumdur (Jacobs ve ark., 2007). Bu bölge nörovasküler varyasyonlar açısından oldukça zengindir (Shelley ve ark., 2019). Bulunduğu bölge gibi, NPK'nın kendisi de oldukça fazla varyasyona sahiptir (Panjnoush ve ark., 2016; Von Arx ve Lozanoff, 2017). NPK literatürde aksiyel, sagittal, koronal planlarda birçok şekilde sınıflandırılmıştır (Bornstein ve ark., 2011; Fernández-Alonso ve ark., 2014; Görürgöz ve Öztaş, 2021). Bu sınıflandırmalardan da görüleceği üzere, NPK'ı sadece "V" ya da "Y" şeklinde bir kanal olarak tanımlamak tüm NPK varyasyonlarını kapsamamaktadır (Friedrich ve ark., 2015). Bu varyasyon kapasitesinden dolayı varyasyon durumunun tespiti yapılacak klinik işlemler açısından oldukça önem taşımaktadır (Liang ve ark., 2009). NPK; lokal anestezi, palatal cerrahi, dental implant cerrahisi, yarık damak gibi konjenital defektler ve bunların onarımı, meziodensler, patent NPD veya Nazopalatin Kist gibi patolojik oluşumların varlığı gibi klinik işlem ve durumlarda önemlidir (Liang ve ark., 2009; Von Arx ve Lozanoff, 2017; Lake ve ark., 2018; Fitzpatrick ve Downs, 2022). Kanal yapısının bilinmesi oluşabilecek komplikasyonları önleyebilmek adına önem taşımaktadır (Jacobs ve ark., 2007; Bornstein ve ark., 2011; Bernades-Mayordomo, Guijarro-Martínez ve Hernández-Alfaro, 2013; Fernández-Alonso ve ark., 2015). Bu nedenle bu tez çalışmasında NPK ve NPK'nın dallanma durumu konu alındı.

NPK konvansiyonel görüntüleme yöntemlerinden periapikal ve okluzal radyografi gibi intraoral radyografi teknikleri, panoramik radyografi gibi ekstraoral radyografi teknikleri ile (Mallya ve Lam, 2019); ileri görüntüleme yöntemleri olaraksa, KIBT, BT (Cavalcanti ve ark., 1999; Mraiwa ve ark., 2004; Mardinger ve ark., 2008; Liang ve ark., 2009), MRG (Jacobs ve ark., 2007; Liang ve ark., 2009), Mikro-BT (Song ve ark., 2009; Fukuda ve ark., 2015) ve NPK kisti varlığında USG (Orhan ve Ünsal, 2021) yardımıyla görüntülenebilir. KIBT, NPK gibi kemik yapıların izlenmesinde etkili yollardan biri olarak karşımıza çıkmaktadır (Bornstein ve ark., 2011). KIBT, BT'ye göre daha az radyasyon dozuna sahip olması, daha hızlı tarama süresine sahip olması, izotropik vokseller sayesinde daha gerçeğe yakın boyutta görüntü elde edilmesi gibi avantajlara sahiptir (Venkatesh ve Elluru, 2017).

Ayrıca 2B radyografilerde olduğu gibi anatomik yapıların gözlenmesini engelleyen süperpozisyon, magnifikasyon, distorsiyon varlığı gibi önemli dezavantajlar içermeyen bir görüntüleme modalitesidir (Honey ve ark., 2007). Bu sebeplerden dolayı bu çalışmada NPK'nın izlendiği KIBT görüntüleri kullanıldı.

Tüm bu bilgiler göz önünde bulundurularak, bu tez çalışmasında KIBT görüntülerinde NPK'nın ve dallanma durumunun tespitinde yapay zekanın performansı değerlendirildi. Çalışmamızın sonuçlarına göre yapay zeka sistemleri ile KIBT görüntülerinde NPK'nın ve dallanma durumunun mükemmel yakın derecede ayırt edilebildiği görülmüştür. Buradan yola çıkarak yapay zeka sistemlerinin KIBT görüntülerinde NPK'nın ve dallanma durumunun tespiti için kullanılabilir olduğunu düşünmekteyiz.

Yapay zeka, günümüzde diş hekimliğinde de kullanımı giderek artan bir teknoloji olarak karşımıza çıkmaktadır (Özkesici ve Yılmaz, 2021). Ağız, Diş ve Çene Radyolojisi alanında da ağız hastalıklarının teşhisi, radyolojik olarak anatomik yapıların morfolojilerinin incelenmesi gibi pek çok konuda yapay zeka algoritmaları ile araştırmalar yapılmıştır (Sağlam, 2021; Türk, 2021). Fakat bu çalışma kapsamında yapılan literatür taramasında NPK segmentasyonunu ve dallanma durumunu yapay zeka ile değerlendiren bir çalışmaya rastlanmamıştır.

Gün geçtikçe artan veri miktarı da göz önünde bulundurulduğunda, yapay zeka çözümleri sayesinde eksik veya yanlış teşhis oranının düşürülmesi ve hekimlerin iş yükünün azaltılmasının mümkün olacağı öngörülmektedir. Bunun yanı sıra, literatürde yapay zeka ile insan gözünden daha ayrıntılı gözlem yapmanın mümkün olduğu belirtilmiştir (Katne ve ark., 2019; Yaji, Prasad ve Pai, 2019). Yapay zekanın bu denli geliştirilmeye açık olması, önemli bir potansiyeli işaret etmektedir. Bu potansiyele rağmen, yapay zeka teknolojileri aşılması gereken bir çok da zayıflığı da bünyesinde barındırmaktadır. Örneğin makine öğrenmesi doğal zekanın aksine dar bir görev odaklanmasına sahiptir (Martín Noguerol ve ark., 2019).

Makine öğrenmesinde yapay zeka bir radyolog gibi eğitim ile deneyim kazanarak öğrenebilir (Kohli ve ark., 2017). Ancak güncel yapay zeka algoritmaları

hastanın bir bütün olarak değerlendirilmesine aşına olmadığı gibi bir hekimin beyninde gerçekleşen subjektif çağrışımları bünyesinde gerçekleştiremez (Martín Noguerol ve ark., 2019). Bu da yapay zeka konusunda daha fazla çalışma yapılması gerekliliğini ortaya koymaktadır.

Yapay zeka ile hem iki boyutlu hem de üç boyutlu görüntüleme modalitelerinin kullanıldığı bir çok çalışma mevcuttur (Sağlam, 2021; Türk, 2021). Ağız, Diş ve Çene Radyolojisi alanında başlangıçta 2 boyutlu tekniklerle alakalı çalışmalar yaygınken, özellikle 3 boyutlu bir görüntüleme modalitesi olan KIBT popülerleştikçe, yapay zeka çalışmalarında kullanımı da artmıştır (Hung ve ark., 2020). Özellikle uygun eğitimi almamış, az tecrübeye sahip hekimlerce KIBT görüntüleri yanlış yorumlanıyor olma ihtimali mevcuttur (Parker ve ark., 2017). Bunun önüne geçebilmek için diş hekimliği pratiğinde KIBT görüntülerinde segmentasyon ve lezyon tespiti için otomasyonun sağlanmasının gerekliliği ortaya çıkmıştır. Dental işleyişin düzene girerek hızlanması; daha iyi, objektif, tekrarlanabilir radyolojik değerlendirilme yapılabilmesi; iş yükünün azalması; yapay zekanın ve KIBT'ye entegre edilmesi ile mümkün olabilir (Mureşanu ve ark., 2022). Yapay zeka algoritmalarının kullanılması ile tanı etkinliği arttırılabileceği öngörülebilir.

Yapay zeka sistemlerinin gün geçtikçe güvenilirliğinin, hızının, hassasiyetinin arttığı ve daha akıllı sistemler haline geldikleri literatürde bildirilmiştir (Özkesİcİ ve Yılmaz, 2021). Daha fazla yeni veri girişiyle yapay zeka algoritmalarının geliştirilebilir ve güvenilir olduklarının doğrulanması, yapay zeka algoritmaları yapılan çalışmalarda tatmin edici performans göstermelerine rağmen, gereklidir (Jayalekshmy ve ark., 2020).

Yapay zekanın bahsi geçen sahip olduğu potansiyel faydalar ve eksik yanlarının giderilebilmesi için geliştirilmesinin gerekli olduğu göz önünde bulunduruldu. Buna ek olarak yapay zeka ile ilgili mevcut umut vadeci sonuçlar göz önüne alındı ve bu tez çalışmasında yapay zeka performansının değerlendirilmesi planlandı. Bunun için yapay zeka mimarisi olarak YOLOv5x-seg algoritmasının kullanılması tercih edildi.

Genel anlamda YOLO algoritmaları başarılı nesne algılama algoritmaları olarak karşımıza çıkmaktadır (Zhiqiang ve Jun, 2017; Jiang ve ark., 2022). YOLOv5 kendisinden önceki versiyonlardan farklı olarak farklı bir yapay zeka kütüphanesi ve programlama dili olarak Pytorch'u ve Python'u kullanmaktadır (Redmon ve Farhadi, 2018; Jocher ve ark., 2021). Önceki yapılan YOLOv5 kullanılan segmentasyon çalışmalarında tek aşamalı olanlarda mevcut YOLOv5 algoritmalarından yeni algoritmalar türetilerek YOLOv5 kullanılmıştır (Wang, Li ve Zheng, 2022). Çift aşamalı olanlarda ise YOLOv5'i nesne algılama için kullanılıp segmentasyon işlemi için başka algoritmalar kullanılmıştır (Mseddi ve ark., 2021). YOLOv5 algoritmasına son yapılan resmi güncelleme ile gelen sürümdeki segmentasyon özelliğini değerlendiren herhangi bir literatür çalışmasına rastlanmamıştır.

Wang ve arkadaşları yaptıkları bir çalışmada, YOLOv5 bazlı YOLO-OCv2 algoritmasını tanıtmışlardır. Bu çalışmada nesne algılama modeline dayalı nesne algılama ve segmentasyon işlemlerini eş zamanlı yapabilen bir model geliştirmişlerdir. Bu modeli eğitmek için, 223 hastaya ait etiketlenmiş 5100 BT kesiti kullanmışlardır. Nesne algılama ve segmentasyon işlemlerini farklı mimariler ile gerçekleştirerek değerlendirmişlerdir. Segmentasyon işlemini FCN, SegNet, U-Net, Deeplabv2 mimarileri ile kıyaslamışlar ve mIoU ve mAP değerlerini diğer mimarilerden daha yüksek olarak bulmuşlardır. Sonuç olarak, tanıttıkları YOLOv5 algoritmasının semantatik segmentasyon için öneriler de teknik açıdan YOLOv5 algoritmasının instance segmentasyonda kullanılabileceğini bildirilmişlerdir (Wang, Li ve Zheng, 2022). Bu sonuçlardan yola çıkıldığında, YOLOv5 modifikasyonu ile edilen sonuçlarda YOLOv5'in nesne algılama işleminin yanısıra segmentasyon işlemini de başarılı gerçekleştirebileceği görülmektedir. Bu noktada YOLOv5'in son resmi güncelleme ile gelen segmentasyon özelliğinin test edilmesine ihtiyaç duyulmaktadır. Bu nedenle bu tez çalışmamızda YOLOv5 ile segmentasyon işlemi uygulanmıştır ve çalışmamızın sonuçları YOLOv5 algoritmasının segmentasyon işlemi için oldukça başarılı bir mimari olduğunu göstermiştir.

Bunun yanı sıra YOLO algoritmaları hızlı olma özellikleriyle de öne çıkan mimariler olmaları nedeniyle(Jiang ve ark., 2022) segmentasyon işleminde de daha kısa sürede doğru sonuçlar elde edilmesini sağlayabileceğini düşünmekteyiz.

Minem ve arkadaşları, yaptıkları çalışmada görüntü segmentasyonu için 8 farklı ESA eğitim stratejisini karşılaştırmışlardır. Ayrıca anatomik oluşumlarının oryantasyonunun segmentasyon performansı üzerine etkisini de incelemiştirler. Bu çalışma için, rastgele yerleşimli temas etmeyen küçük silindirik boşluklar içeren büyük silindir fantomlar ve antropomorfik fantom kafa modellerinin KIBT görüntüleri kullanılmıştır. Kıyaslanan eğitim stratejileri ise 2B ESA'larını eğitmek için 3 strateji (aksiyel, sagittal ve koronal planlarda); arttırılmış 2B dört eğitim stratejisi (3 kanallı veya 5 kanallı 2.5B yaklaşımı, çoğunluk oylaması ve rastgele yönlendirilmiş 2B kesitleri) ve son olarak da tamamen üç boyutlu(3B) eğitim stratejisi olmak üzere sekiz stratejiden oluşturulmuştur. Eğitilmiş tüm segmentasyonların performansı dice benzerlik katsayısı ile değerlendirilmiştir. Ek olarak tüm segmentlere ayrılmış deneysel KIBT görüntüleri ile altın standart KIBT görüntüleri 3B sanal modeller olarak rekonstrükte edilip oryantasyona dayalı yüzey karşılaştırmaları kullanılarak değerlendirilmiştir. Genel olarak en iyi performans çoğunluk oylaması stratejisinde elde edilmiştir. Bununla beraber yazarlar 2B eğitim stratejilerini kullanırken eğer üç ayrı ESA'yi eğitmek mümkün değil ise çalışılan anatomik yapının baskın yönelimine dik olan eksen üzerinden eğitim yapılmasını önermiş, böylece segmentasyon performansının optimize edilebileceğini belirtmişlerdir. Tıbbi görüntü bölütleme için ESA eğitim stratejileri seçerken veya oluştururken çalışılacak yapının uzamsal özelliklerinin dikkate alınmasının gerektiğinin altını çizmişlerdir (Minem ve ark., 2021). Bahsi geçen bilgiler göz önünde bulundurularak, tez çalışmamızda; NPK uzanımına en dik kesit olan aksiyel kesitler üzerinde 2B eğitim stratejisi ile çalışılması tercih edilmiştir. Tez çalışma sonuçları incelendiğinde segmentasyon performansının mükemmele yakın derecede yüksek olduğu görülmektedir. Bu yüksek performansa seçilen eğitim stratejisinin ve seçilen kesit planının etkisinin olduğunu düşünmekteyiz.

Ek olarak 3B ESA'larının Grafik İşlem Birimi (GPU) olarak bilinen özel grafik işlemciler dolayısıyla bellek kısıtlamasına maruz kalırlar ki bu da birim

boyutunu sınırlar. Bu sebeple çoğu 3B ESA orijinal görüntüden kırılmış görüntüler ya da küçük yamalar halinde eğitmek durumunda kalınır (Milletari, Navab ve Ahmadi, 2016; Wachinger, Reuter ve Klein, 2018). Başka bir deyişle 3B ESA'ları henüz segmentasyon yaklaşımı için yeteri derecede geliştirilememiştir (Kamnitsas ve ark., 2017). Bunlar dışında çok fazla eğitilebilir parametreye sahip olmaları (Kamnitsas ve ark., 2017), uydurmaya yatkınlığı ve daha uzun eğitim sürelerini beraberinde getirir (Zhou ve ark., 2018). Bu dezavantajlar çerçevesinde arttırılmış 2B eğitim stratejileri oluşturulmuştur. Ancak arttırılmış 2B eğitim stratejilerinin birden çok planı ayrı ayrı değerlendirmeyi gerektirir (Prasoon ve ark., 2013; Roth ve ark., 2014; Ben-Cohen ve ark., 2016). 2B ESA sistemlerin daha kolay uygulanabilir olduğu söylenebilir. Bu noktada 2B yöntemler açısından yüksek başarıya sahip ve hızlı bir algoritmanın var olması oldukça önemlidir. Bu özelliklere sahip algoritma olarak YOLOv5 gösterilebildiğini düşünmekteyiz.

Eğitim veri setinin örneklem büyüklüğü derin öğrenmede oldukça önem taşımaktadır. Yapay zeka öğrenimi eğitim veri setinin örneklem sayısı arttıkça bir noktaya kadar hızla yükselme gösterir. Sonrasında ise öğrenim artışı plato çizer (Cho ve ark., 2015). Bu çalışmada veri miktarının yeterli olmasının segmentasyondaki başarısının yüksek olmasına katkısı olduğunu düşünmekteyiz. Ayrıca makine öğreniminin başarısı eğitim veri setlerinin örnek kalitesinden de etkilenmektedir. Eğitim veri setlerinin oluşturulması ise zaman, maliyet ve kaynak gerektirir (Litjens ve ark., 2017). Bu nedenle bu tez çalışmasında örnek kalitesini arttırmak adına katı dahil etme ve hariç tutma kriterleri kullanıldı ve eğitim veri setleri oluşturulurken yeterli miktar ve değerlendirilebilirliğe sahip örneklem miktar ve kalitesi tercih edilmiştir.

Karmaşık klinik görüntülerinden oluşan veri kümelerinin, DESA'larının çalışma performansını sınırlaması (Gao ve ark., 2020); çalışmamızda dallanma varlığında NPK tespitinin performansının, dallanma olmayan duruma göre bir miktar düşük olması ile ilişkilendirilebilir. Ancak yine de dallanma varlığında NPK tespit performansı değerleri kabul edilebilir sınırların oldukça üzerinde ve yeterli olarak bulunmuştur.

Çalışma sonuçlarımızda Grup-1 mAP ve AUC dışındaki tüm değerler 1'e çok yakın olarak bulunmuştur. Bu sonuçlardan hareketle YOLOv5 modelinin segmentasyon özelliğinin oldukça başarılı ve KIBT'lerde kullanılabilir olduğu yargısına varılmıştır.

Grup-1'de mAP, AUC değerleri 0.7930 ve 0.8841 olarak bulunmuştur. Bu değerler YOLOv5 modelinin dallanmayı oldukça iyi ve yeterli derecede ayırt edebildiğini göstermiştir. Yalnızca sistem tahmin doğruluğu Grup-1 için Grup-2'ninki kadar yüksek değildir. Grup-1'de Grup-2 değerleri kadar yüksek değer elde edilememesi, dallanma varlığında kanal yapısının daha kompleks hale gelebileceği ve tüm bu kompleks yapının yapay zeka tarafından algılanmasının güç olabileceği yargısına dayandırılabilir. Ayrıca bu çalışmada Grup-2'nin kesit sayısı, Grup-1'e göre oldukça fazladır. Kesit sayıları arasındaki farkın, bu sonuçlara ve Grup-2'deki tüm değerlerin daha başarılı çıkmasına sebep olmuş olabileceğini düşünmekteyiz.

Literatürde KIBT görüntülerinde NPK'nın yapay zeka sistemleri ile segmente edildiği başka bir çalışmaya rastlanmamıştır. Ancak literatürde benzer çalışma kurgusuna sahip KIBT ve panoramik radyografi görüntüleri üzerinde çalışan araştırmalar mevcuttur.

Duman ve arkadaşları, 188 KIBT görüntüsü üzerinde sagittal kesitlerde sella tursika segmentasyonu ve sınıflamasında evrimsel sinir ağının performansını değerlendirmişlerdir. Bunun için U-Net ve Tensorflow 1 destekli PyTorch ve GoogleNet Inception V3 algoritması kullanıldı. Sella tursika segmentasyonu için Duyarlılık, Kesinlik ve F1 Skorları 1 bulunmuştur. Sella tursicayı düz, oval ve yuvarlak olarak sınıflandırdıklarında ise Duyarlılık, Kesinlik ve F1 Skorları düz olanda sırasıyla 1, 0.95, 0.98; oval olanda sırasıyla 0.83, 0.92, 0.88; yuvarlak olanda ise sırasıyla 0.94, 0.90, 0.83 olarak bulunmuştur (Duman ve ark., 2022). Bu tez çalışmasında ise Grup-1 için sırasıyla 0.9680, 0.9953, 0.9815; Grup-2 için ise 0.9827, 0.9975, 0.9900 olarak saptanmıştır. Sonuçlar, Duman ve arkadaşlarının çalışması ile paralellik göstermektedir. Bu noktada YOLOv5 algoritmasının segmentasyon için başarılı bir model olduğu ve NPK'nın segmentasyon

performansının farklı dallanma durumlarında mükemmel derecede tespit ettiği sonucuna varılabilir.

Verhelst ve arkadaşları, toplam 190 KIBT görüntüsünden oluşan veri seti kullandıkları mandibular kanal segmentasyonu yaptıkları çalışmalarında; 3B-UNet kullanarak iki evrimsel sinir ağını kombinleyip bulut tabanlı bir yapay zeka sistemine entegre etmişler ve kullanıcı tarafından işlenmiş yapay zeka segmentasyonları ile mevcut klinik standart olarak kabul edilen yarı otomatik segmentasyonu karşılaştırmışlardır. Çalışmalarında duyarlılık 0.993, kesinlik 0.952, IoU 0.946 değerlerini bulmuşlardır (Verhelst ve ark., 2021).

Kanti Dhar ve arkadaşları, 187 KIBT görüntüsü kullandıkları mandibular kanal segmentasyonu yaptıkları 3B-UNet kullandıkları çalışmalarında duyarlılık 0.51, kesinlik 0.63, f1 skor 0.575, IoU 0.7 değerlerini bulmuşlardır (Kanti Dhar ve Yu, 2021).

Lahoud ve arkadaşları 235 KIBT görüntüsü kullandıkları mandibular kanal segmentasyonu yaptıkları 3B-UNet bazlı algoritma kullandıkları çalışmalarında duyarlılık 0.792, kesinlik 0.782, mIoU 0.636 değerlerini bulmuşlardır (Lahoud ve ark., 2022).

Kwak ve arkadaşları 61 eğitim veri seti kullandıkları mandibular kanal segmentasyonu yaptıkları ön eğitimli SegNet, 2B-UNet, 3B-UNet kullandıkları çalışmalarında elde ettikleri mIoU değerleri 2B SegNet için 0.49116(ön eğitimli-orijinal filtre sayısı ile); 2B U-Net için 0.38462(azaltılmış filtre sayısı ile), 0.45984(orijinal filtre sayısı ile), 0.42043(ön eğitimli-orijinal filtre sayısı ile), 0.41125(ön eğitimli, orijinal filtre sayısı ile, bitişik 2 resim kullanılarak); 3B- UNet için 0.57721 değerlerini bulmuşlardır (Kwak ve ark., 2020).

Tez çalışmamızın sonuçları ise; Kanti Dhar ve ark.larının, Lahoud ve ark.larının, Kwak ve ark.larının sonuçlarından daha yüksek bulunmuştur. Verhelst ve arkadaşları çalışmalarında 3B-UNet kullanarak iki evrimsel sinir ağını kombinleyip bulut tabanlı bir yapay zeka sistemine entegre ederek yapay zeka modellerini

oluşturmuşlardır. Bu tez çalışmasında ise tek aşamalı YOLOv5x-seg modeli kullanılmış ve bulunan sonuçlar, kullanılan yapay zeka mimari farkına rağmen Verhelst ve arkadaşlarının çalışması ile uyumluydu. Bu sade mimariye rağmen sonuçların yakın olması, YOLOv5 mimarisinin segmentasyon modelinin segmentasyon yeteneğinin yüksek olduğunu gösterebileceğini düşünmekteyiz.

Ayrıca yapılan bir çalışmada R-CNN, Faster R-CNN, SSD, YOLOv3 ve RetinaNet dahil on farklı derin öğrenme algılama modeli kullanarak panoramik radyografi görüntüleri üzerinde dental restorasyon tespiti ve sınıflaması yapılmıştır. Diş restorasyonları, protez ve implant olmak üzere 3 sınıfa ayırmak üzere panoramik radyograf üzerinde 684 nesne kullanılmıştır. Bu on model için 0.5 eşik değerdeki mAP değerleri 0,755-0,973 değişmekte olarak bulunmuştur. İçlerinde en iyi performans gösteren Faster R-CNN RegnetX 0.973 mAP ve 0.952 AUC değerlerinde saptanmıştır (Çelik ve Çelik, 2022). Çalışmada bulunan en iyi performans gösteren yapay zeka modelinin sonuçları ve tez çalışmamızın NPK’da dallanma olmayan grubunun sonuçları ile paralellik gösterdiği, NPK’da dallanma olan grubun sonuçlarında ise olmayan grubun değerlerden daha düşük sonuçlar elde edildiği görülmesine rağmen, başarılı olarak değerlendirilebilecek düzeydedir. Bulgularımız göz önünde bulundurulduğunda; YOLOv5x-seg’in NPK sınıflandırılmasında yeterli olduğu ancak daha fazla veri ile eğitilerek daha da iyileştirilebileceği sonucuna varılabilir.

Bu çalışmanın limitasyonları; yapay zekanın NPK’ın sadece dallanma varlığı veya yokluğu durumundaki performansının değerlendirilmiş olması, tek bir KIBT cihazına ait verilerle NPK’ın yapay zekaya tanıtılmış olması, yapay zekanın NPK’ın farklı sınıflandırmalarındaki performansının değerlendirilmemiş olması ve etiketleme için mouse ile poligon başka bir deyişle serbest çizim tekniğinin kullanılmış olmasıdır. Daha gelişmiş çizim cihazları ve teknikleri, etiketleme performansını arttırabilir.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, 200 KIBT görüntüsü üzerinde YOLOv5x-seg algoritması kullanılarak NPK segmentasyonu gerçekleştirildi ve NPK'nın dallanma durumu değerlendirildi. Ayrıca bu çalışma KIBT görüntülerinde NPK'nın yapay zeka ile değerlendirildiği ilk çalışma olma özelliğini taşımaktadır.

Çalışmanın sonuçlarına göre:

1. Duyarlılık, kararlılık, f1 skoru ve IoU değerleri; NPK dallanması olan grup için sırasıyla 0.9680, 0.9953, 0.9815, 0.9636 olarak, NPK dallanması olmayan grup için sırasıyla 0.9827, 0.9975, 0.9900, 0.9803 olarak bulundu. Bu değerler incelendiğinde dallanma olmayan grupta daha yüksek segmentasyon başarısı bulunmak üzere hem dallanma olan, hem de dallanma olmayan NPK aksiyel kesitleri için YOLOv5x-seg modelinin segmentasyon başarısının mükemmele yakın derecede yüksek olduğu söylenebilir.
2. mAP ve AUC değerleri ise; NPK dallanması olan grup için sırasıyla 0.7930, 0.8841, NPK dallanması olmayan grup için sırasıyla 0.9637, 0.9510 olarak bulundu. NPK aksiyel kesitlerinde YOLOv5x-seg modelinin NPK dallanma varlığında ve daha az veri seti ile eğitildiğinde NPK tespitinin güçleşip, tahmin doğruluğunun daha azalmış olduğu söylenebilir ve YOLOv5x-seg modelinin NPK dallanma varlığı ve daha az veri seti ile eğitildiğinde bile, gayet başarılı ve kabul edilebilir sınırların üzerinde bir tahmin doğruluğu elde ettiğini düşünmekteyiz.
3. YOLOv5x algoritmasının KIBT görüntülerinde NPK ve dallanma durumunun tespitinde oldukça başarılı bir yapay zeka modeli olduğu görülmüştür. İleri çalışmalarla geliştirildiğinde, klinik olarak da kullanılabilir hale gelebileceğini ve bu sayede daha az deneyime sahip hekimler için oldukça yardımcı olabileceğini düşünmekteyiz.

4. Temelde nesne algılama algoritması olan YOLOv5 algoritmasının segmentasyon özelliği, yeni geliştirilmesine rağmen oldukça başarılı sonuçlara ulaştığı ancak geliştirilmeye açık olduğunu ve umut vadettiğini düşünmekteyiz. İleri çalışmalarda NPK'nın sınıflandırmalarının yapay zeka ile değerlendirilmesinin hedeflenebileceğini düşünmekteyiz.



ÖZET

Konik Işınlı Bilgisayarlı Tomografi Görüntülerinde Nazopalatin Kanal Tespitinin Yapay Zeka ile Karşılaştırılması

NPK; maksiller santral keserlerin posteriorunda, orta hatta lokalizasyon gösteren bir anatomik oluşumdur. Kanalin morfolojisi oldukça fazla ve önemli miktarda değişkenlik göstermektedir. NPK bir ileri görüntüleme yöntemi olan KIBT ile de görüntülenebilir. Bunun yanı sıra, KIBT yapay zeka alanında da pek çok çalışmada kullanılmaktadır. Yapay zeka, veriler aracılığıyla öğrenebilen makinelerin problemleri çözmeleri amaçlanarak geliştirilmiş sistemlerdir. YOLO (You Only Look Once) oldukça hızlı bir nesne tanıma mimarisi olarak karşımıza çıkmaktadır. YOLO'nun 5. Versiyonu olan YOLOv5'in son resmi güncellemesinde segmentasyon modelleri kullanıma sunulmuştur. Bu Tez çalışmasının amacı KIBT görüntülerinde NPK'nın segmente edilmesi ve dallanma durumunun değerlendirilmesi açısından gözlemci ile yapay zekayı karşılaştırmaktır.

Çalışma kapsamında, KIBT görüntüleri retrospektif olarak tarandı. Taranan görüntülerden, NPK'da dallanma var olan 100 kanala ve dallanma olmayan 100 kanala ait, toplamda 200 KIBT görüntüsü seçildi. Bu KIBT görüntülerine ait aksiyel kesit çerçeve görüntüsü etiketleme işlemi için kullanıldı. Görüntülerdeki NPK dallanma varlığı ya da yokluğu durumuna göre sınıflandırılarak etiketlendi. Bu tez çalışması, YOLOv5x-seg modeli ile yapıldı. Görüntülerin %80'i olan 160 tanesi eğitim veri seti, %10'u olan 20 tanesi doğrulama veri seti, %10'u olan 20 tanesi test veri seti olarak ayrıldı. YOLOv5x-seg modeli ile 800 epoch (eğitim turu) yapılarak eğitim gerçekleştirildi. Karışıklık Matrisi kullanılarak, yapay zekanın performansı değerlendirildi. Gözlemci içi güvenilirlik için 2 hafta sonra görüntülerin % 20'si dallanma varlığı ya da yokluğu durumu açısından tekrar sınıflandırıldı.

YOLOv5x-seg modelinin NPK tespiti ve sınıflandırılması için duyarlılık, kesinlik, F1 skoru ve IoU değerleri; NPK dallanması olan grup için sırasıyla 0.9680, 0.9953, 0.9815, 0.9636 olarak, NPK dallanması olmayan grup için sırasıyla 0.9827, 0.9975, 0.9900, 0.9803 olarak bulundu. mAP ve AUC değerleri ise; NPK dallanması olan grup için sırasıyla 0.7930, 0.8841, NPK dallanması olmayan grup için sırasıyla 0.9637, 0.9510 olarak bulundu.

YOLOv5x-seg modelinin NPK dallanma varlığı ve daha az veri seti ile eğitildiğinde bile, mükemmel olmasa da gayet başarılı ve kabul edilebilir sınırların üzerinde bir tahmin doğruluğu elde ettiğini düşünmekteyiz. Temelde nesne algılama algoritması olan YOLOv5 algoritmasının segmentasyon özelliği, yeni geliştirilmesine rağmen oldukça başarılı sonuçlara ulaştığı ancak geliştirilmeye açık ve umut vaadedici olduğunu düşünmekteyiz.

Anahtar Sözcükler: Nazopalatin Kanal, Konik Işınlı Bilgisayarlı Tomografi, YOLOv5, Segmentasyon

SUMMARY

Comparison of Nasopalatine Canal Detection in Cone-Beam Computed Tomography Images with Artificial Intelligence

NPC is an anatomical formation localized in the midline posterior to the maxillary central incisors. The morphology of the canal varies considerably. NPC can also be visualized with CBCT, an advanced imaging modality. In addition, CBCT is used in many studies in the field of artificial intelligence. Artificial intelligence is systems developed with the aim of solving problems by machines that can learn through data. YOLO (You Only Look Once) is a rapid object detection framework. In the last official update of YOLOv5, version 5 of YOLO, segmentation models were introduced. The aim of this thesis study is to compare the observer and artificial intelligence in terms of segmentation of NPC and branching status assessment in CBCT images.

In the study, the CBCT images were retrospectively scanned. A total of 200 CBCT images of 100 canals with branching in NPC and 100 canals without branching were selected. The axial sectional frame view of these CBCT images was used for labeling. They were labeled and classified according to the presence or absence of NPC branching in the images. This thesis study was done with YOLOv5x-seg model. 80% of the images were divided into 160 training datasets, 10% validation datasets, and 10% test datasets. The training was done by making 800 epochs (training tours) with the YOLOv5x-seg model. Using the Confusion Matrix, the performance of the AI was evaluated. For intra-observer reliability, after 2 weeks, 20% of the images were reclassified for presence or absence of branching.

Sensitivity, precision, F1 score, and IoU values for NPC detection and classification of the YOLOv5x-seg model; It was found as 0.9680, 0.9953, 0.9815, 0.9636 for the group with NPC branching, and as 0.9827, 0.9975, 0.9900, 0.9803 for the group without NPC branching, respectively. mAP and AUC values are found as 0.7930 and 0.8841 for the group with NPC branching, respectively, 0.9637 and 0.9510 for the group without NPC branching.

We think that even when the YOLOv5x-seg model is trained with the presence of NPC branching and fewer datasets, it achieves a good, if not perfect, prediction accuracy above acceptable limits. We think that the segmentation feature of the YOLOv5 algorithm, which is basically an object detection algorithm, has achieved quite successful results despite its recent development, but is open to development and promising.

Keywords: Nasopalatine Canal, Cone-Beam Computed Tomography, YOLOv5, Segmentation

KAYNAKLAR

- AĞYAR Z (2015). Yapay sinir ağlarının kullanım alanları ve bir uygulama. *Mühendis ve Makine* **56**: 22-23.
- AKGÜL A ve ÇEVIK O (2003). İstatistiksel Analiz Teknikleri Emek Ofset Matbaacılık: Ankara.
- AKST J (2019). A primer: artificial intelligence versus neural networks. *Inspiring Innovation: The Scientist Exploring Life* **65802**.
- AKTAN A, GÜNGÖR E, ÇİFTÇİ M ve İŞMAN Ö (2015). Diş hekimliğinde konik işinli bilgisayarlı tomografi kullanımı. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi* **25**: 71-76.
- ALAN A ve KARABATAK M (2020). Veri Seti - Sınıflandırma İlişkisinde Performansa Etki Eden Faktörlerin Değerlendirilmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* **32**: 531-40.
- ALLARD R, DE VRIES K ve VAN DER KWAST W (1982). Persisting bilateral nasopalatine ducts: A developmental anomaly: Report of a case. *Oral Surgery, Oral Medicine, Oral Pathology* **53**: 24-26.
- AOUN G ve NASSEH I (2016). Mesiodens within the nasopalatine canal: an exceptional entity. *Clinics and practice* **6**: 903.
- ARSLAN A ve İNCE R (1993). Geriye yayılma yapay sinir ağı kullanılarak betonarme kolonların tasarımı. *Turkish Journal of Engineering and Enviromental Sciences* **2**: 127-35.
- ARTZI Z, NEMCOVSKY C E, BITLITUM I ve SEGAL P (2000). Displacement of the incisive foramen in conjunction with implant placement in the anterior maxilla without jeopardizing vitality of nasopalatine nerve and vessels: a novel surgical approach. *Clinical Oral Implants Research: Novel development* **11**: 505-10.

ASLAN M (2021). Derin Öğrenme ile Şeftali Hastalıkların Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*: 540-46.

AYDOĞMUŞ ERIK A, ERIK C E ve YILDIRIM D (2019a). Konik ışınlı bilgisayarlı tomografi görüntülerinde voksel boyutunun doğrusal ölçümlere etkisinin değerlendirilmesi. *Selcuk Dental Journal, ODMFR 2019 Kongre Kitapçığı Özel Sayısı 6*: 234-38.

AYDOĞMUŞ ERIK A, ERIK C E ve YILDIRIM D (2019b). Resiprokal ve Rotasyonel Hareket ile Çalışan Yeni Nesil Tek Eğe Sistemlerinin Şekillendirebilme Etkinliklerinin Konik Işınlı Bilgisayarlı Tomografi Kullanarak Karşılaştırılması. *Süleyman Demirel Üniversitesi Sağlık Bilimleri Dergisi 10*: 93-98.

BADR F ve JADU F (2022). Performance of artificial intelligence using oral and maxillofacial CBCT images: A systematic review and meta-analysis. *Nigerian Journal of Clinical Practice 25*: 1918.

BAŞARAN E.(2020). Timpanik Membran Görüntü Analizi Ve Yapay Zeka Kullanılarak Sanal Otitis Media Tanı Sisteminin Geliştirilmesi. *Karabük Üniversitesi*

BAŞARAN G ve CAGIL G (2022). Koruyucu Gözlük Kullanımının Görüntü İşleme Yöntemiyle Tespit Edilmesi. *El-Cezerî Fen ve Mühendislik Dergisi 9*: 86-95.

BELLAIRS A (1951). Observations on the incisive canaliculi and nasopalatine ducts. *British dental journal 91*: 281-91.

BELLMAN R (1978). An introduction to artificial intelligence: can computers think? *Thomson Course Technology*.

BEN-COHEN A, DIAMANT I, KLANG E, AMITAI M ve GREENSPAN H (2016). Fully convolutional network for liver segmentation and lesions detection. *Deep learning and data labeling for medical applications Springer 77-85*.

BERNADES-MAYORDOMO R, GUIJARRO-MARTÍNEZ R ve HERNÁNDEZ-ALFARO F (2013). Volumetric CBCT analysis of the palatine process of the anterior maxilla: a potential source for bone grafts. *Int J Oral Maxillofac Surg 42*: 406-10.

- BORNSTEIN M M, BALSIGER R, SENDI P ve VON ARX T (2011). Morphology of the nasopalatine canal and dental implant surgery: a radiographic analysis of 100 consecutive patients using limited cone-beam computed tomography. *Clin Oral Implants Res* **22**: 295-301.
- BOZÜYÜK T.(2005). Yapay Zeka Teknolojilerinin Endüstrideki Uygulamaları. Marmara Üniversitesi
- BROOME W C ve SEYMOUR JR F W (1976). Partially patent nasopalatine ducts: report of cases. *Journal of endodontics* **2**: 279-82.
- BROTCHIE P (2019). Machine learning in radiology. *J Med Imaging Radiat Oncol* **63**: 25-26.
- BUTRYMOWICZ A, WEISSTUCH A, ZHAO A, AGARWAL J ve PINHEIRO-NETO C D (2016). Endoscopic endonasal greater palatine artery cauterization at the incisive foramen for control of anterior epistaxis. *Laryngoscope* **126**: 1033-8.
- CASADO P L, DONNER M, PASCARELLI B, DEROCY C, DUARTE M E L ve BARBOZA E P (2008). Immediate dental implant failure associated with nasopalatine duct cyst. *Implant Dentistry* **17**: 169-75.
- CAVALCANTI M G, YANG J, RUPRECHT A ve VANNIER M W (1999). Accurate linear measurements in the anterior maxilla using orthoradially reformatted spiral computed tomography. *Dentomaxillofac Radiol* **28**: 137-40.
- CECCHETTI F, OTTRIA L, BARTULI F, BRAMANTI N ve ARCURI C (2012). Prevalence, distribution, and differential diagnosis of nasopalatine duct cysts. *ORAL & implantology* **5**: 47.
- CHANDRA R K, ROHMAN G T ve WALSH W E (2008). Anterior palate sensory impairment after septal surgery. *Am J Rhinol* **22**: 86-8.
- CHEN L-C, PAPANDREOU G, KOKKINOS I, MURPHY K ve YUILLE A L (2017). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. *IEEE transactions on pattern analysis and machine intelligence* **40**: 834-48.

- CHO J, LEE K, SHIN E, CHOY G ve DO S (2015). How much data is needed to train a medical image deep learning system to achieve necessary high accuracy? *arXiv preprint arXiv:1511.06348*.
- CHOI S H, JUNG S N, CHA J Y, HU K S, KIM K D, BAIK H S ve HWANG C J (2016). Changes in the craniofacial complex and alveolar bone height of young adults: Applications to dental medicine. *Clinical Anatomy* **29**: 1011-17.
- CHOLLET F (2017). Xception: Deep learning with depthwise separable convolutions " In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-58.
- COOK J A (2017). ROC curves and nonrandom data. *Pattern Recognition Letters* **85**: 35-41.
- ÇELİK B ve ÇELİK M E (2022). Automated detection of dental restorations using deep learning on panoramic radiographs. *Dentomaxillofacial Radiology* **51**: 20220244.
- DANFORTH R A, DUS I ve MAH J (2003). 3-D volume imaging for dentistry: a new dimension. *Journal of the California Dental Association* **31**: 817-23.
- DE OLIVEIRA-SANTOS C, RUBIRA-BULLEN I R, MONTEIRO S A, LEÓN J E ve JACOBS R (2013). Neurovascular anatomical variations in the anterior palate observed on CBCT images. *Clinical oral implants research* **24**: 1044-48.
- DE VOS W, CASSELMAN J ve SWENNEN G (2009). Cone-beam computerized tomography (CBCT) imaging of the oral and maxillofacial region: a systematic review of the literature. *International journal of oral and maxillofacial surgery* **38**: 609-25.
- DEMIRHAN A, KILİÇ Y A ve İNAN G (2010). Tıpta yapay zeka uygulamaları.
- DENG X, LIU Q, DENG Y ve MAHADEVAN S (2016). An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Information Sciences* **340**: 250-61.
- DIRICAN A (2014). TANI TESTİ PERFORMANSLARININ DEĞERLENDİRİLMESİ VE KIYASLANMASI. *Cerrahpaşa Tıp Dergisi* **32**: 25-30.

DOLCI C, PUCCIARELLI V, GIBELLI D M, CODARI M, MARELLI S, TRIFIRÒ G, PINI A ve SFORZA C (2018). The face in marfan syndrome: A 3D quantitative approach for a better definition of dysmorphic features. *Clinical Anatomy* **31**: 380-86.

DUMAN Ş B, SYED A Z, CELIK OZEN D, BAYRAKDAR İ Ş, SALEHI H S, ABDELKARIM A, CELIK Ö, ESER G, ALTUN O ve ORHAN K (2022). Convolutional Neural Network Performance for Sella Turcica Segmentation and Classification Using CBCT Images. *Diagnostics* **12**: 2244.

EL-NAGGAR A K, CHAN J K ve GRANDIS J R (2017). WHO classification of head and neck tumours.

ELLIOTT K A, FRANZESE C B ve PITMAN K T (2004). Diagnosis and surgical management of nasopalatine duct cysts. *Laryngoscope* **114**: 1336-40.

EPPLEY B L ve DELFINO J J (1988). Bilateral nasopalatine ducts of the premaxilla. *International journal of oral and maxillofacial surgery* **17**: 360-62.

ERGEZER H, DIKMEN M ve ÖZDEMİR E (2003). Yapay sinir ağları ve tanıma sistemleri. *PiVOLKA* **2**: 14-17.

ERGÜN E ve KILIÇ K (2021). Derin öğrenme ile artırılmış görüntü seti üzerinden cilt kanseri tespiti. *Black Sea Journal of Engineering and Science* **4**: 192-200.

FALCI S G M, VERLI F D, CONSOLARO A ve SANTOS C R R D (2013). Morphological characterization of the nasopalatine region in human fetuses and its association to pathologies. *Journal of Applied Oral Science* **21**: 250-55.

FERNÁNDEZ-ALONSO A, SUÁREZ-QUINTANILLA J A, MUINELO-LORENZO J, BORNSTEIN M M, BLANCO-CARRIÓN A ve SUÁREZ-CUNQUEIRO M M (2014). Three-dimensional study of nasopalatine canal morphology: a descriptive retrospective analysis using cone-beam computed tomography. *Surgical and Radiologic Anatomy* **36**: 895-905.

FERNÁNDEZ-ALONSO A, SUÁREZ-QUINTANILLA J A, RAPADO-GONZÁLEZ O ve SUÁREZ-CUNQUEIRO M M (2015). Morphometric differences of nasopalatine canal based on 3D classifications: descriptive analysis on CBCT. *Surg Radiol Anat* **37**: 825-33.

FITZPATRICK T H ve DOWNS B W (2022). Anatomy, Head and Neck, Nasopalatine Nerve. *StatPearls* StatPearls Publishing

Copyright © 2022, StatPearls Publishing LLC.: Treasure Island (FL).

FRIEDRICH R E, LAUMANN F, ZRNC T ve ASSAF A T (2015). The Nasopalatine Canal in Adults on Cone Beam Computed Tomograms-A Clinical Study and Review of the Literature. *In Vivo* **29**: 467-86.

FUKUDA M, MATSUNAGA S, ODAKA K, OOMINE Y, KASAHARA M, YAMAMOTO M ve ABE S (2015). Three-dimensional analysis of incisive canals in human dentulous and edentulous maxillary bones. *International journal of implant dentistry* **1**: 1-8.

GAO L, ZHANG L, LIU C ve WU S (2020). Handling imbalanced medical image data: A deep-learning-based one-class classification approach. *Artificial Intelligence in Medicine* **108**: 101935.

GARCIA-GARCIA A, ORTS-ESCOLANO S, OPREA S, VILLENA-MARTINEZ V ve GARCIA-RODRIGUEZ J (2017). A review on deep learning techniques applied to semantic segmentation. *arXiv preprint arXiv:1704.06857*.

GOODFELLOW I, BENGIO Y ve COURVILLE A (2016). Deep learning MIT press.

GÖRÜRGÖZ C ve ÖZTAŞ B (2021). Anatomic characteristics and dimensions of the nasopalatine canal: a radiographic study using cone-beam computed tomography. *Folia Morphologica* **80**: 923-34.

GUO F, QIAN Y ve SHI Y (2021). Real-time railroad track components inspection based on the improved YOLOv4 framework. *Automation in construction* **125**: 103596.

GÜNDÜZ G ve CEDİMOĞLU İ H (2019). Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini. *Sakarya University Journal of Computer and Information Sciences* **2**: 9-17.

HAN J, KAMBER M ve PEI J (2012). Data mining: Concepts and techniques Morgan Kaufmann Publishers.

HASHIMOTO D, ROSMAN G, RUS D ve MEIRELES O (2018). Machine learning in Surgery: Promises and Perils. *Ann. Surg* **268**: 70-76.

HILL W O ve DARLOW H (1945). Bilateral perforate nasopalatine communication in the human adult. *The Journal of Laryngology & Otology* **60**: 160-65.

HISATOMI M, ASAUMI J, KONOUCI H, MATSUZAKI H ve KISHI K (2001). MR imaging of nasopalatine duct cysts. *Eur J Radiol* **39**: 73-6.

HONEY O B, SCARFE W C, HILGERS M J, KLUEBER K, SILVEIRA A M, HASKELL B S ve FARMAN A G (2007). Accuracy of cone-beam computed tomography imaging of the temporomandibular joint: comparisons with panoramic radiology and linear tomography. *Am J Orthod Dentofacial Orthop* **132**: 429-38.

HUNG K, MONTALVAO C, TANAKA R, KAWAI T ve BORNSTEIN M M (2020). The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofacial Radiology* **49**: 20190107.

HURT B, KLIGERMAN S ve HSIAO A (2020). Deep Learning Localization of Pneumonia: 2019 Coronavirus (COVID-19) Outbreak. *J Thorac Imaging* **35**: W87-w89.

HWANG J J, JUNG Y H, CHO B H ve HEO M S (2019). An overview of deep learning in the field of dentistry. *Imaging Sci Dent* **49**: 1-7.

IAMANDOIU A V, MUREŞAN A N ve RUSU M C (2022). Detailed Morphology of the Incisive or Nasopalatine Canal. *Anatomia* **1**: 75-85.

JACOB S, ZELANO B, GUNGOR A, ABBOTT D, NACLERIO R ve MCCLINTOCK M K (2000). Location and gross morphology of the nasopalatine duct in human adults. *Archives of Otolaryngology–Head & Neck Surgery* **126**: 741-48.

JACOBS R, LAMBRICHTS I, LIANG X, MARTENS W, MRAIWA N, ADRIAENSENS P ve GELAN J (2007). Neurovascularization of the anterior jaw bones revisited using high-resolution magnetic resonance imaging. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology* **103**: 683-93.

JAPKOWICZ N (2011). Performance evaluation for learning algorithms Cambridge University Press: Cambridge.

JAYALEKSHMY R, UNNITHAN J J, KUMAR A M ve MAJID S A (2020). Artificial intelligence-finding new frontiers in oral and maxillofacial radiology. *Journal of Dental and Orofacial Research* **16**: 32-38.

JIANG P, ERGU D, LIU F, CAI Y ve MA B (2022). A Review of Yolo algorithm developments. *Procedia Computer Science* **199**: 1066-73.

JOCHER G, CHAURASIA A, STOKEN A, BOROVEC J, NANOCODE012., KWON Y, MICHAEL K, TAOXIE., FANG J, IMYHXY., LORNA., YIFU Z, WONG C, V. A, MONTES D, WANG Z, FATI C, NADAR J, LAUGHING, UNGLVKITDE, SONCK V, TKIANAI., YXNONG., SKALSKI P, HOGAN A, NAIR D, STROBEL M ve JAIN M (2022). ultralytics/yolov5: v7.0 - YOLOv5 SOTA Realtime Instance Segmentation. *Zenodo* **v7.0**.

JOCHER G, STOKEN A, BOROVEC J, CHRISTOPHER S ve LAUGHING L C (2021). ultralytics/yolov5: v4. 0-nn. SiLU () activations, Weights & Biases logging, PyTorch Hub integration. *Zenodo*.

KAHEEL H, HUSSEIN A ve CHEHAB A (2021). AI-based image processing for COVID-19 detection in chest CT scan images. *AI-Based CT-Scan Analysis for COVID-19 Detection* **2**.

KAMNITSAS K, LEDIG C, NEWCOMBE V F, SIMPSON J P, KANE A D, MENON D K, RUECKERT D ve GLOCKER B (2017). Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. *Medical image analysis* **36**: 61-78.

KANTI DHAR M ve YU Z (2021). Automatic tracing of mandibular canal pathways using deep learning. *arXiv e-prints*: arXiv: 2111.15111.

KATNE T, KANAPARTHI A, GOTOOR S G, MUPPIRALA S, DEVARAJU R R ve GANTALA R (2019). Artificial Intelligence: Demystifying Dentistry – The Future and Beyond.

KHANAGAR S B, AL-EHAIDEB A, MAGANUR P C, VISHWANATHAIAH S, PATIL S, BAESHEN H A, SARODE S C ve BHANDI S (2021). Developments, application, and performance of artificial intelligence in dentistry - A systematic review. *J Dent Sci* **16**: 508-22.

KHANNA S (2010). Artificial intelligence: contemporary applications and future compass. *International dental journal* **60**: 269-72.

KHANNA S S ve DHAIMADE P A (2017). Artificial intelligence: transforming dentistry today. *Indian J Basic Appl Med Res* **6**: 161-67.

KNECHT M, HÜTTENBRINK K-B, KITNER T, HUMMEL T, BELEITES T ve WITT M (2005). Morphological and radiologic evaluation of the human nasopalatine duct. *Annals of Otolaryngology & Laryngology* **114**: 229-32.

KOÇER B.(2012). Transfer Öğrenmede Yeni Yaklaşımlar. Selçuk Üniversitesi.

KOHLI M, PREVEDELLO L M, FILICE R W ve GEIS J R (2017). Implementing machine learning in radiology practice and research. *American journal of roentgenology* **208**: 754-60.

KWAK G H, KWAK E-J, SONG J M, PARK H R, JUNG Y-H, CHO B-H, HUI P ve HWANG J J (2020). Automatic mandibular canal detection using a deep convolutional neural network. *Scientific Reports* **10**: 5711.

LAHOUD P, DIELS S, NICLAES L, VAN AELST S, WILLEMS H, VAN GERVEN A, QUIRYNEN M ve JACOBS R (2022). Development and validation of a novel artificial intelligence driven tool for accurate mandibular canal segmentation on CBCT. *Journal of Dentistry* **116**: 103891.

LAKE S, IWANAGA J, KIKUTA S, OSKOUIAN R J, LOUKAS M ve TUBBS R S (2018). The Incisive Canal: A Comprehensive Review. *Cureus* **10**: e3069.

LANDIS J R ve KOCH G G (1977). The measurement of observer agreement for categorical data. *biometrics*: 159-74.

LANGLAND O E ve LANGLAIS R P (1997). Principles of Dental Imaging Williams & Wilkins: Baltimore.

LARHEIM T A ve WESTESSON P L (2006). Maxillofacial imaging anatomy Springer: Berlin Heidelberg.

LEBOUCQ H L F (1881). Le canal naso-palatin chez l'homme Hayez.

LECUN Y, BENGIO Y ve HINTON G (2015). Deep learning. *nature* **521**: 436-44.

LEE J-G, JUN S, CHO Y-W, LEE H, KIM G B, SEO J B ve KIM N (2017). Deep learning in medical imaging: general overview. *Korean journal of radiology* **18**: 570-84.

LEE J-H, HAN S-S, KIM Y H, LEE C ve KIM I (2020). Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral surgery, oral medicine, oral pathology and oral radiology* **129**: 635-42.

LEE J, GHARAIBEH Y, KOLLURU C, ZIMIN V N, DALLAN L A P, KIM J N, BEZERRA H G ve WILSON D L (2020). Segmentation of coronary calcified plaque in intravascular OCT images using a two-step deep learning approach. *IEEE access* **8**: 225581-93.

LEE S, LEE C ve LEE S (2013). Patent nasopalatine duct mimicking nasopalatine duct cyst. *Kor J Oral Maxillofac Pathol* **37**: 167-74.

LIANG X, JACOBS R, MARTENS W, HU Y, ADRIAENSENS P, QUIRYNEN M ve LAMBRICHTS I (2009). Macro- and micro-anatomical, histological and computed tomography scan characterization of the nasopalatine canal. *J Clin Periodontol* **36**: 598-603.

LIANG X, LAMBRICHTS I, CORPAS L, POLITIS C, VRIELINCK L, MA G W ve JACOBS R (2008). Neurovascular disturbance associated with implant placement in the anterior mandible and its surgical implications: literature review including report of a case. *Chinese Journal of Dental Research* **11**: 56.

LITJENS G, KOOI T, BEJNORDI B E, SETIO A A A, CIOMPI F, GHAFORIAN M, VAN DER LAAK J A W M, VAN GINNEKEN B ve SÁNCHEZ C I (2017). A survey on deep learning in medical image analysis. *Medical image analysis* **42**: 60-88.

LOPEZ A R, GIRO-I-NIETO X, BURDICK J ve MARQUES O (2017). Skin lesion classification from dermoscopic images using deep learning techniques " In *2017 13th IASTED international conference on biomedical engineering (BioMed)*, 49-54. IEEE.

LUCA A R, URSULEANU T F, GHEORGHE L, GRIGOROVICI R, IANCU S, HLUSNEAC M ve GRIGOROVICI A (2022). Impact of quality, type and volume of data used by deep learning models in the analysis of medical images. *Informatics in Medicine Unlocked*: 100911.

LUNDNER A S ve WARUNEK S P (2006). Patent nasopalatine ducts after rapid maxillary expansion. *American journal of orthodontics and dentofacial orthopedics* **130**: 96-99.

MALLYA S M ve LAM E W N (2019). *White and Pharoah's Oral Radiology: Principles and Interpretation* Elsevier: St Louis, Missouri.

MARCUS G (2018). Deep learning: A critical appraisal. *arXiv preprint arXiv:1801.00631*.

MARDINGER O, NAMANI-SADAN N, CHAUSHU G ve SCHWARTZ-ARAD D (2008). Morphologic changes of the nasopalatine canal related to dental implantation: a radiologic study in different degrees of absorbed maxillae. *J Periodontol* **79**: 1659-62.

MARTÍN NOGUEROL T, PAULANO-GODINO F, MARTÍN-VALDIVIA M T, MENIAS C O ve LUNA A (2019). Strengths, Weaknesses, Opportunities, and Threats Analysis of Artificial Intelligence and Machine Learning Applications in Radiology. *J Am Coll Radiol* **16**: 1239-47.

MASHYAKHY M ve ABU-MELHA A S (2021). Analysis of Bilateral Symmetry of Root Canal Anatomy in Permanent Dentition: An In Vivo CBCT Study in a Saudi Arabian Population. *The Journal of Contemporary Dental Practice* **22**: 867-75.

MCCARTHY J (2007). What is artificial intelligence?

MCCREA S J (2014). Nasopalatine duct cyst, a delayed complication to successful dental implant placement: diagnosis and surgical management. *J Oral Implantol* **40**: 189-95.

MEYER W (1958). Histologie der Mundhöhle. *Die Zahn-, Mund-und Kieferheilkunde* **1**: 232-306.

MILLETARI F, NAVAB N ve AHMADI S-A (2016). V-net: Fully convolutional neural networks for volumetric medical image segmentation " In *2016 fourth international conference on 3D vision (3DV)*, 565-71. IEEE.

MINAEE S, BOYKOV Y Y, PORIKLI F, PLAZA A J, KEHTARNAVAZ N ve TERZOPOULOS D (2021). Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*.

MINNEMA J, WOLFF J, KOIVISTO J, LUCKA F, BATENBURG K J, FOROUZANFAR T ve VAN EIJNATTEN M (2021). Comparison of convolutional neural network training strategies for cone-beam CT image segmentation. *Computer Methods and Programs in Biomedicine* **207**: 106192.

MOOR J (2006). The Dartmouth College artificial intelligence conference: The next fifty years. *. Ai Magazine* **27**: 87-91.

MOSS H D, HELLSTEIN J W ve JOHNSON J D (2000). Endodontic considerations of the nasopalatine duct region. *Journal of endodontics* **26**: 107-10.

MOSSAZ J, KLOUKOS D, PANDIS N, SUTER V G, KATSAROS C ve BORNSTEIN M M (2014). Morphologic characteristics, location, and associated complications of maxillary and mandibular supernumerary teeth as evaluated using cone beam computed tomography. *European journal of orthodontics* **36**: 708-18.

MOZZO P, PROCACCI C, TACCONI A, TINAZZI MARTINI P ve BERGAMO ANDREIS I (1998). A new volumetric CT machine for dental imaging based on the cone-beam technique: preliminary results. *European radiology* **8**: 1558-64.

MRAIWA N, JACOBS R, VAN CLEYNENBREUGEL J, SANDERINK G, SCHUTYSER F, SUETENS P, VAN STEENBERGHE D ve QUIRYNEN M (2004). The nasopalatine canal revisited using 2D and 3D CT imaging. *Dentomaxillofac Radiol* **33**: 396-402.

- MSEDDI W S, GHALI R, JMAL M ve ATTIA R (2021). Fire Detection and Segmentation using YOLOv5 and U-NET " In *2021 29th European Signal Processing Conference (EUSIPCO)*, 741-45.
- MUREŞANU S, ALMĂŞAN O, HEDEŞIU M, DIOŞAN L, DINU C ve JACOBS R (2022). Artificial intelligence models for clinical usage in dentistry with a focus on dentomaxillofacial CBCT: a systematic review. *Oral Radiology*: 1-23.
- MURPHY K P (2012). Machine learning: a probabilistic perspective MIT press.
- NABIYEV V V (2012). Yapay zeka: insan-bilgisayar etkileşimi Seçkin Yayıncılık.
- NERI E, DE SOUZA N ve BRADY A (2019). What the radiologist should know about artificial intelligence—an ESR white paper. *Insights Imaging* 10.
- NERI E, DE SOUZA N, BRADY A, BAYARRI A A, BECKER C D, COPPOLA F, VISSER J ve EUROPEAN SOCIETY OF R (2019). What the radiologist should know about artificial intelligence – an ESR white paper. *Insights into Imaging* 10: 44.
- NETTER F H (2022). Netter Atlas of Human Anatomy: A Systems Approach-E-Book Elsevier Health Sciences.
- NICHOLS J A, HERBERT CHAN H W ve BAKER M A (2019). Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophysical reviews* 11: 111-18.
- NOYES H J (1935). Nasopalatine duct and Jacobson's organ in newborn infants. *J Dent Res* 15: 155.
- ORHAN K ve ÜNSAL G (2021). Applications of Ultrasonography in Maxillofacial/Intraoral Inflammatory and Cystic Lesions. In: ORHAN K (ed.), *Ultrasonography in Dentomaxillofacial Diagnostics* Springer International Publishing: Cham 259-73.
- OZCAN I (2017). Diş Hekimliğinde Radyolojinin Esasları: Konvansiyonelden Dijitale İstanbul Tıp Kitabevi: İstanbul.

OZENNE B, SUBTIL F ve MAUCORT-BOULCH D (2015). The precision–recall curve overcame the optimism of the receiver operating characteristic curve in rare diseases. *Journal of clinical epidemiology* **68**: 855-59.

ÖZKAN İ ve ÜLKER E (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi* **6**: 85-104.

ÖZKESİCİ M Y ve YILMAZ S (2021). ORAL VE MAKSİLLOFASİYAL RADYOLOJİ'DE YAPAY ZEKA. *Sağlık Bilimleri Dergisi* **30**: 346-51.

PANDL K D, THIEBES S, SCHMIDT-KRAEPELIN M ve SUNYAEV A (2020). On the convergence of artificial intelligence and distributed ledger technology: A scoping review and future research agenda. *IEEE access* **8**: 57075-95.

PANJNOUSH M, NOROUZI H, KHEIRANDISH Y, SHAMSHIRI A R ve MOFIDI N (2016). Evaluation of Morphology and Anatomical Measurement of Nasopalatine Canal Using Cone Beam Computed Tomography. *J Dent (Tehran)* **13**: 287-94.

PARKER J M, MOL A, RIVERA E M ve TAWIL P Z (2017). Cone-beam computed tomography uses in clinical endodontics: observer variability in detecting periapical lesions. *Journal of endodontics* **43**: 184-87.

PHILBERT R F ve SANDHU N S (2020). Nonodontogenic cysts. *Dental Clinics* **64**: 63-85.

PİRİM A G H (2006). Yapay zeka. *Yaşar Üniversitesi E-Dergisi* **1**: 81-93.

PITHON M M (2011). Asymptomatic patent nasopalatine ducts after rapid maxillary expansion. *Journal of Craniofacial Surgery* **22**: 1333-35.

PRASOON A, PETERSEN K, IGEL C, LAUZE F, DAM E ve NIELSEN M (2013). Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network " In *International conference on medical image computing and computer-assisted intervention*, 246-53. Springer.

PURNAMA I K E, HERNANDA A K, RATNA A A P, NURTANIO I, HIDAYATI A N, PURNOMO M H, NUGROHO S M S ve RACHMADI R F (2019). Disease classification

based on dermoscopic skin images using convolutional neural network in teledermatology system " In *2019 International Conference on Computer Engineering, Network, and Intelligent Multimedia (CENIM)*, 1-5. IEEE.

RADLANSKI R J, EMMERICH S ve RENZ H (2004). Prenatal morphogenesis of the human incisive canal. *Anat Embryol (Berl)* **208**: 265-71.

RAGHOEBAR G M, DEN HARTOG L ve VISSINK A (2010). Augmentation in proximity to the incisive foramen to allow placement of endosseous implants: a case series. *Journal of oral and maxillofacial surgery* **68**: 2267-71.

RAWENGEL G (1923). Die Nasen-Gaumengänge und andere epitheliale Gebilde im vorderen Teile des Gaumens bei Neugeborenen und Erwachsenen. *Archiv für mikroskopische Anatomie* **97**: 507-22.

REDMON J, DIVVALA S, GIRSHICK R ve FARHADI A (2016). You only look once: Unified, real-time object detection " In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 779-88.

REDMON J ve FARHADI A (2017). YOLO9000: better, faster, stronger " In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 7263-71.

REDMON J ve FARHADI A (2018). Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.

REENA, BANDYOPADHYAY K H ve PAUL A (2016). Postoperative analgesia for cleft lip and palate repair in children. *J Anaesthesiol Clin Pharmacol* **32**: 5-11.

RODRIGUES M T V, MUNHOZ E A, CARDOSO C L, JUNIOR O F ve DAMANTE J H (2009). Unilateral patent nasopalatine duct: a case report and review of the literature. *American Journal of Otolaryngology* **30**: 137-40.

ROPER-HALL H ve DENT B (1941). Patent incisive canal. *Br Dent J* **71**: 306-09.

ROSENQUIST J ve NYSTRÖM E (1992). Occlusion of the incisal canal with bone chips. A procedure to facilitate insertion of implants in the anterior maxilla. *International journal of oral and maxillofacial surgery* **21**: 210-11.

ROTH H R, LU L, SEFF A, CHERRY K M, HOFFMAN J, WANG S, LIU J, TURKBAY E ve SUMMERS R M (2014). A new 2.5 D representation for lymph node detection using random sets of deep convolutional neural network observations " In *International conference on medical image computing and computer-assisted intervention*, 520-27. Springer.

SACHDEVA R, DONKERS S J ve KIM S Y (2016). Angelman syndrome: a review highlighting musculoskeletal and anatomical aberrations. *Clinical Anatomy* **29**: 561-67.

SAĞLAM H.(2021). DERİN ÖĞRENME YÖNTEMİNE DAYALI YAPAY ZEKÂ ALGORİTMALARIYLA KONİK IŞINLI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE DİŞLERİN TESPİT EDİLMESİ VE NUMARALANDIRILMASI. ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ.

SAMALA R K, HEANG-PING C, HADJIISKI L, HELVIE M A, RICHTER C D ve CHA K H (2019). Breast Cancer Diagnosis in Digital Breast Tomosynthesis: Effects of Training Sample Size on Multi-Stage Transfer Learning Using Deep Neural Nets. *IEEE Trans Med Imaging* **38**: 686-96.

SAMUEL A L (1959). Machine learning. *The Technology Review* **62**: 42-45.

SAMUEL A L (1967). Some studies in machine learning using the game of checkers. II—Recent progress. *IBM Journal of research and development* **11**: 601-17.

SCARFE W C ve FARMAN A G (2008). What is cone-beam CT and how does it work? *Dental Clinics of North America* **52**: 707-30.

SCHAITKIN B, STRAUSS M ve HOUCK J R (1987). Epistaxis: medical versus surgical therapy: a comparison of efficacy, complications, and economic considerations. *The Laryngoscope* **97**: 1392-96.

SCHER E (1994). Use of the incisive canal as a recipient site for root form implants: preliminary clinical reports. *Implant Dentistry* **3**: 38-41.

SCHWARTZ S (2012). Local anesthesia in pediatric dentistry. *Revised January* **6**.

SCHWENDICKE F A, SAMEK W ve KROIS J (2020). Artificial intelligence in dentistry: chances and challenges. *Journal of dental research* **99**: 769-74.

SEN D, CHAKRABARTI R, CHATTERJEE S, GREWAL D ve MANRAI K (2020). Artificial intelligence and the radiologist: the future in the Armed Forces Medical Services. *BMJ Mil Health* **166**: 254-56.

SEVLI O (2019). Göğüs Kanseri Teşhisinde Farklı Makine Öğrenmesi Tekniklerinin Performans Karşılaştırması. *Avrupa Bilim ve Teknoloji Dergisi*: 176-85.

SHABBIR J ve ANWER T (2018). Artificial intelligence and its role in near future. *arXiv preprint arXiv:1804.01396*.

SHELLEY A, TINNING J, YATES J ve HORNER K (2019). Potential neurovascular damage as a result of dental implant placement in the anterior maxilla. *British dental journal* **226**: 657-61.

SHI S, WANG Q, XU P ve CHU X (2016). Benchmarking state-of-the-art deep learning software tools " In *2016 7th International Conference on Cloud Computing and Big Data (CCBD)*, 99-104. IEEE.

SHIN D-J ve KIM J-J (2022). A Deep Learning Framework Performance Evaluation to Use YOLO in Nvidia Jetson Platform. *Applied Sciences* **12**: 3734.

SICHER H ve DUBRUL E (1975). Oral Anatomy CV Mosby Company: St Louis.

SIVOLELLA S, VALENTE M, GASPARINI E ve STELLINI E (2013). Nasopalatine duct cyst as a complication of dental implant placement: a case report. *Minerva stomatologica* **62**: 235-39.

SONG W C, JO D I, LEE J Y, KIM J N, HUR M S, HU K S, KIM H J, SHIN C ve KOH K S (2009). Microanatomy of the incisive canal using three-dimensional reconstruction of microCT images: an ex vivo study. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod* **108**: 583-90.

SRIVASTAVA N, HINTON G, KRIZHEVSKY A, SUTSKEVER I ve SALAKHUTDINOV R

(2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research* **15**: 1929-58.

STANDRING S (2005). Gray's Anatomy Churchill Livingstone: Edinburg.

STEYERBERG E W (2010). Validation of prediction models. In: STEYERBERG E W (ed.), *Clinical Prediction Models: A Practical Approach to Development, Validation, and Updating* Springer: New York pp. 299-310.

SUTER V G, SENDI P, REICHART P A ve BORNSTEIN M M (2011). The nasopalatine duct cyst: an analysis of the relation between clinical symptoms, cyst dimensions, and involvement of neighboring anatomical structures using cone beam computed tomography. *Journal of oral and maxillofacial surgery* **69**: 2595-603.

SUZUKI K (2017). Overview of deep learning in medical imaging. *Radiol Phys Technol* **10**: 257-73.

TAKESHITA K, FUNAKI K, JIMBO R ve TAKAHASHI T (2013). Nasopalatine duct cyst developed in association with dental implant treatment: A case report and histopathological observation. *Journal of oral and maxillofacial pathology: JOMFP* **17**: 319.

TASCHIERI S, WEINSTEIN T, ROSANO G ve DEL FABBRO M (2012). Morphological features of the maxillary incisors roots and relationship with neighbouring anatomical structures: possible implications in endodontic surgery. *International journal of oral and maxillofacial surgery* **41**: 616-23.

TOMAK L ve YÜKSEL B (2009). İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması. *Journal of Experimental and Clinical Medicine* **27**.

TORRES M G G, DE FARO VALVERDE L, VIDAL M T A ve CRUSOÉ-REBELLO I M (2016). Trifid nasopalatine canal: case report of a rare anatomical variation and its surgical implications. *Revista Cubana de Estomatología* **53**: 67-70.

TUR A.(2021). Derin öğrenme yöntemleri kullanarak etkin ayırık işaret dili tanıma sistemi geliştirme. Ankara Üniversitesi.

- TURING A M (1950). I.—COMPUTING MACHINERY AND INTELLIGENCE. *Mind* **LIX**: 433-60.
- TÜRK E.(2021). GÖMÜLÜ MANDİBULAR ÜÇÜNCÜ MOLAR DİŞLERİN POZİSYON ÖZELLİKLERİNİN YAPAY ZEKA İLE DEĞERLENDİRİLMESİ. SÜLEYMAN DEMİREL ÜNİVERSİTESİ.
- TYNDALL D A ve BROOKS S L (2000). Selection criteria for dental implant site imaging: a position paper of the American Academy of Oral and Maxillofacial radiology. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology* **89**: 630-37.
- UCUZAL H.(2020). Yapay Zekaya Dayalı Anlamsal Video İşleme Yöntemlerinin Tıpta Kullanılabilirliğinin Araştırılması. İnönü Üniversitesi.
- UZUN T (2020). YAPAY ZEKA VE SAĞLIK UYGULAMALARI. *İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* **3**: 80-92.
- VALSTAR M ve VAN DEN AKKER H (2008). Patent nasopalatine duct: a diagnostic pitfall. *British Journal of Oral and Maxillofacial Surgery* **46**: 304-05.
- VENKATESH E ve ELLURU S V (2017). Cone beam computed tomography: basics and applications in dentistry. *J Istanbul Univ Fac Dent* **51**: S102-s21.
- VERHELST P-J, SMOLDERS A, BEZNIK T, MEEWIS J, VANDEMEULEBROUCKE A, SHAHEEN E, VAN GERVEN A, WILLEMS H, POLITIS C ve JACOBS R (2021). Layered deep learning for automatic mandibular segmentation in cone-beam computed tomography. *Journal of Dentistry* **114**: 103786.
- VIEHWEG T L, ROBERSON J B ve HUDSON J W (2006). Epistaxis: diagnosis and treatment. *J Oral Maxillofac Surg* **64**: 511-8.
- VON ARX T ve LOZANOFF S (2017). Clinical Oral Anatomy Springer: Switzerland.

VON ARX T, LOZANOFF S, SENDI P ve BORNSTEIN M M (2013). Assessment of bone channels other than the nasopalatine canal in the anterior maxilla using limited cone beam computed tomography. *Surgical and Radiologic Anatomy* **35**: 783-90.

VON ARX T, SCHAFFNER M ve BORNSTEIN M (2018). Patent nasopalatine ducts: an update of the literature and a series of new cases. *Surgical and Radiologic Anatomy* **40**: 165-77.

VON LANZ T ve WACHSMUT K (1985). *Praktische Anatomie* Springer: Berlin-Heidelberg-New York.

WACHINGER C, REUTER M ve KLEIN T (2018). DeepNAT: Deep convolutional neural network for segmenting neuroanatomy. *NeuroImage* **170**: 434-45.

WANG X, LI H ve ZHENG P (2022). Automatic Detection and Segmentation of Ovarian Cancer Using a Multitask Model in Pelvic CT Images. *Oxidative Medicine and Cellular Longevity* **2022**.

WILLIAMS P L, WARWICK R, DYSON M ve BANNISTER L H (1989). *Gray's Anatomy* Churchill Livingstone: Edinburgh.

YAJI A, PRASAD S ve PAI A (2019). Artificial intelligence in dento-maxillofacial radiology. *Acta Scientific Dental Sciences* **3**: 116-21.

YASAV M.(2008). Yapay Sinir Ağlarıyla Yüz Mimiklerinin Tanınması. Yıldız Teknik Üniversitesi
YILMAZ A (2020). Yapay Zeka İnkılap Kitabevi Yayın San. Tic. A.Ş.

YU J ve ZHANG W (2021). Face mask wearing detection algorithm based on improved YOLO-v4. *Sensors* **21**: 3263.

YÜCE F.(2022). Derin Öğrenme Kullanılarak Bite-Wing Radyografilerde Pulpal Kalsifikasyonların Tespiti Necmettin Erbakan Üniversitesi.

ZHIQIANG W ve JUN L (2017). A review of object detection based on convolutional neural network. *2017 36th Chinese Control Conference (CCC)*: 11104-09.

ZHOU X, YAMADA K, KOJIMA T, TAKAYAMA R, WANG S, ZHOU X, HARA T ve FUJITA H
(2018). Performance evaluation of 2D and 3D deep learning approaches for automatic
segmentation of multiple organs on CT images " In *Medical Imaging 2018: Computer-Aided
Diagnosis*, 520-25. Spie.



EKLER

Ek 1-Etik Kurul Kararı



Ek 2- Aydınlatılmış Onam Formu

	AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ HASTA AYDINLATILMIŞ ONAM FORMU						
Dok. No	HD.RB.42	Yürürlük Tarihi	30.03.2018	Rev. Tar/No	08.03.2022 / 01	Sayfa No	1 / 3

Sayın hasta/velisi/vasisi,

- Lütfen bu belgeyi dikkatlice okuyunuz.
- Tıbbi durumunuz ve hastalığınızın tedavisi için size önerilen işlem/ tedaviler hakkında bilgi sahibi olmak en doğal hakkınızdır.
- Bu açıklamaların amacı sağlığınıza ile ilgili konularda sizi bilgilendirmek ve bu sürece sizi daha bilinçli bir biçimde ortak etmektir.
- Tanısal girişimlerin, tıbbi ve cerrahi tedavilerin yararlarını ve olası risklerini öğrendikten sonra yapılacak işleme rıza göstermek ya da göstermemek kendi kararınıza bağlıdır.
- Arzu ettiğiniz takdirde sağlığınıza ile ilgili tüm bilgi ve dokümanlar size veya uygun göreceğiniz bir yakınınıza verilebilir.
- Okuma-yazma sorunu yaşıyorsanız ya da size yapılacak işlemlere izin verme sürecine sizin belirleyeceğiniz bir kişinin daha katılmasını istiyorsanız, görüşme tanığı olarak belirlediğiniz kişinin katılmasına izin verebilirsiniz.
- Yasal ve tıbbi zorunluluk taşıyan durumlar dışında bilgilendirmeyi reddedebilirsiniz.
- İsteddiğiniz zaman verdiğiniz izni geri çekme hakkına sahipsiniz. Bu durum sizin bundan sonraki tedavinizi hiçbir şekilde aksatmayacaktır. Ancak, yasal açıdan bu hakkınız "tıbbi yönden bir sakınca bulunmaması" şartına bağlıdır. Bu durum gerçekleştiğinde, Aydınlatılmış Onamı Geri Çekme Tutanağı düzenlenerek bu belgenin arkasına eklenecektir.
- Mevcut sistemik hastalıklar, allerjiler, kullanılan ilaçlar ve genel sağlık durumu ile ilgili olarak hekiminizi bilgilendirmeniz gerekmektedir. Herhangi bir konuyu saklamış olmanız veya beyan etmemenizden kaynaklanacak sorumluluk size aittir.
- Sağlık kuruluşumuzun düzeninin ve tedavi programının aksamaması için randevularınıza sadık olmaya ve zamanında gelmeye özen gösteriniz. Gelmeniz mümkün olmadığında, randevunuzu 24 saat öncesinden iptal ettiriniz. Randevu saatinde gelmemeniz durumunda, klinik yoğunluğuna bağlı olarak randevunuz başka bir güne ertelenebilir.

1. BİLGİLENDİRME

Tedavi başlangıcında, tedavi süresince ve kontrol amaçlı olarak tedavi sonrasında diş ve çevre dokuların ayrıntılı olarak incelenebilmesi için dişlerinizden veya çenelerinizden röntgen çekilmesi gerekebilir. Çekilen röntgen filmleri:

- Gözle yapılan muayenede fark edilemeyen çürük alanlarının (örneğin dişler arasındaki çürüklerin) ve mevcut olan dolguların altında gelişen çürük ya da diğer patolojilerin görülmesini sağlar.
- Dişeti hastalığı nedeniyle oluşan kemik kaybı hakkında bilgi verir.
- Kök kanalındaki sorunların görüntülenmesini sağlar.
- Diş kaynaklı enfeksiyonların kemik dokuya yayılıp yayılmadığını gösterir.
- İmplant hazırlığı ve yerleştirilmesinde, ortodontik tedavinin başında ve süresince yararlı ve gereklidir.
- Kemik ve yumuşak dokudaki kist, tümör gibi patolojilerin belirlenmesinde yardımcıdır.

Diş, çene ve yüz bölgenizden istenecek görüntüleme tetkikleri genel ya da ağız sağlığınıza etkileyecek durumların tanısı, tedavi planlaması ve tedavi aşamalarının takibi için gereklidir. Şu anda diş ve çevre dokuların görüntülenmesinde röntgene alternatif bir yöntem yoktur. Kliniklerimizde X- ışını kullanılarak ağız içerisinde ve ağız dışından röntgenler çekilmektedir. İstenecek röntgen tetkiki ve adedini hekiminiz belirler. Bunun yanında gerekli durumlarda 3 boyutlu dental bilgisayarlı tomografi çekilebilir. Röntgen çekiminde kullanılan X-ışını canlı doku için zararlıdır. Bu nedenle hekiminiz sizin tanınız, tedavi planlamanız, tedavi aşamalarınızın takibi ve kontrol amacı ile gereken en az sayıda röntgen isteyecektir.

HAZIRLAYAN	KONTROL	ONAY
KALİTE BİRİMİ	BAŞHEKİM	DEKAN

		AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ HASTA AYDINLATILMIŞ ONAM FORMU					
Dok. No	HD.RB.42	Yürürlük Tarih	30.03.2018	Rev. Tar/No	08.03.2022 / 01	Sayfa No	2 / 3

Çocuk hastalarda (18 Yaş altı) radyografi zorunlu olduğu takdirde, mümkün olan en az sayıda alınır. Olası zararları önlemek için kurşun içerikli malzemeden yapılmış tiroid koruyucu ve batin kısmını da örten kurşun önlük giydirilerek çekim yapılır.

Hamile hastalarda radyografi acil durumlarda ve mümkün olan en az sayıda alınır. Diş hekimliği radyolojisinde X-ışınları yalnızca baş ve boyun bölgesine yönlendirildiğinden, tüm ağız radyografilerinin (14 adet ağız içi film) alınması durumunda bile fetüsün alacağı doz, doğal kaynaklardan alınan dozdaki çok daha düşük düzeydedir.

Ayrıca röntgen çekimi sırasında zararı en aza indirmek amacıyla gerekirse kurşun önlük, tiroid koruyucu gibi ek önlemler alınacaktır.

2. UYGULANACAK İŞLEMLER

• Ağız içi ve çevre dokuların muayenesi	☐
• Ağız içi radyolojik tetkik	☐
• Ağız dışı radyolojik tetkik	☐
• Vitalite testi	☐
• Fotoğraf Çekimi	☐
• Konik Işınli Bilgisayarlı Tomografi (CBCT)	☐
• Manyetik Rezonans Görüntüleme (MRI)	☐
• Ultrasonografi (USG)	☐
• Biyopsi	☐

Tarih:

Hastadan sorumlu hekimin Adı-Soyadı:

Hastadan sorumlu öğretim üyesinin Adı Soyadı:

İmza:

İmza:

3. ONAM (İZİN, RIZA)

Diş Hekimi..... tarafından konulan tanı ve tedavi ile ilgili planlama, alternatif tedaviler, sonuçları, istenmeyen yan etkileri hakkında bilgilendirildim, anladım. Uygulanacak olan tedaviyi kabul edtim.

Tedavi süresinde/sırasında ortaya çıkabilecek yeni durumlarla planlamanın değişebileceği anlatıldı, anladım ve kabul edtim. Tedavi uygulanmadığı takdirde ortaya çıkabilecek olası riskler, tedavinin alternatif uygulamalarına göre maliyet hesapları, gerekli görüldüğü takdirde diğer hekimlerden konsültasyon istenebileceği konularında bilgilendirildim, anladım, kabul edtim.

HAZIRLAYAN	KONTROL	ONAY
KALİTE BİRİMİ	BAŞHEKİM	DEKAN



AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ HASTA AYDINLATILMIŞ ONAM FORMU



Dok. No	HD.RB.42	Yürürlük Tarihi	30.03.2018	Rev. Tar/No	08.03.2022 / 01	Sayfa No	3 / 3
---------	----------	-----------------	------------	-------------	-----------------	----------	-------

Tedavim/vasisi olduğum kişinin tedavisi hakkında merak ettiğim tüm sorulara cevap verildi. Yapılacak tedavilerin başarısının bana da bağlı olduğu, evde üzerime düşen ağız temizliği ve önerilere uymam gerektiği, vazgeçilmesi gereken zararlı alışkanlıklarla ilgili önerileri yerine getirme ve yazılacak reçetelerdeki ilaçları tarife uygun doz ve sürelerde kullanma gerekliliği anlatıldı, anladım ve kabul ettim.

Uygulanacak tedavilerin ağız ve diş sağlığını korumayı amaçladığını, tıbbi hizmetlerin özenle yürütüleceği ancak tıbbi işlemlerde sonucun garanti edilemeyeceği tarafıma anlatıldı, anladım ve kabul ettim. Hasta hakları ve sorumlulukları, hekim hakları ve yükümlülükleri konularında detaylı olarak bilgilendirildim.

(El yazınız ile "okuduğumu anladım, kabul ediyorum" yazınız).

Kimlik bilgilerinin gizli tutulması ve yalnızca eğitim ve araştırma amaçlı kullanılması koşulu ile bana uygulanacak girişim/tedavi sırasında fotoğraf çekilmesine, tıbbi kayıtlarımın kullanılmasına izin (El yazınız ile "veriyorum" ya da "vermiyorum" yazınız.)

Tarih:

Hasta Adı-Soyadı:

T.C. Kimlik No:

İmza:

Hastanın Yasal Temsilcisi (Yakınlık Derecesi) Adı-Soyadı*:

T.C. Kimlik No:

Adres:

Telefon:

İmza:

(*) Yasal Temsilci: Reşit ve/veya mümeyyiz olmayan kişiler yönünden veli veya vasisinin aydınlatılmış onamı gerekir.

HAZIRLAYAN	KONTROL	ONAY
KALİTE BİRİMİ	BAŞHEKİM	DEKAN

ÖZGEÇMİŞ

I-Bireysel Bilgiler

Adı ve Soyadı : Hatice Ahsen DENİZ

