



**BİLGİSAYARLI TOMOGRAFİ
GÖRÜNTÜLERİNDEN OS HYOIDEUM'UN
EFFICIENTNET DERİN ÖĞRENME MODELİ
KULLANILARAK CİNSİYET TAHMİNİ**

**2024
DOKTORA TEZİ
ANATOMİ**

Rukiye Sümeyye BAKICI

**Tez Danışmanı
Doç. Dr. Zülal ÖNER**

**BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN OS HYOIDEUM'UN
EFFICIENTNET DERİN ÖĞRENME MODELİ KULLANILARAK
CİNSİYET TAHMİNİ**

Rukiye Sümeyye BAKICI

**Tez Danışmanı
Doç. Dr. Zülal ÖNER**

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Anatomi Anabilim Dalında
Doktora Tezi
Olarak Hazırlanmıştır**

**KARABÜK
Haziran 2024**

Rukiye Sümeyye BAKICI tarafından hazırlanan “BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN OS HYOIDEUM’UN EFFICIENTNET DERİN ÖĞRENME MODELİ KULLANILARAK CİNSİYET TAHMİNİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Doç. Dr. Zülal ÖNER
Tez Danışmanı, Anatomi Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Anatomi Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 04/06/2024

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Doç. Dr. Zülal ÖNER (İBÜ)
Üye : Doç. Dr. Şeyma TOY (KBÜ)
Üye : Doç. Dr. Serkan ÖNER (İBÜ)
Üye : Doç. Dr. Mahmut ÇAY (UÜ)
Üye : Prof. Dr. Hıdır PEKMEZ (MTÜ)

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Doç. Dr. Zeynep ÖZCAN
Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Rukiye Sümeyye BAKICI

ÖZET

Doktora Tezi

BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN OS HYOIDEUM'UN EFFICIENTNET DERİN ÖĞRENME MODELİ KULLANILARAK CİNSİYET TAHMİNİ

Rukiye Sümeyye BAKICI

**Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Anatomi Anabilim Dalı**

Tez Danışmanı:

Doç. Dr. Zülal ÖNER

Haziran 2024, 55 sayfa

Os hyoideum viscerocranium'un bir parçası olup iskelet sistemindeki diğer kemiklerden farklı olarak yalnızca kaslar ve bağlarla eklenir. Bu kemik yutma, konuşma, regürjitasyonun önlenmesi ve hava yolu bakımı fonksiyonlarında önemlidir. Adli ve biyoarkeolojik bilimlerde iskeletten kimlik tespiti için cinsiyeti bilmek anahtar faktördür. Bu çalışmada, EfficientNet derin öğrenme mimarisi kullanılarak os hyoideum'dan cinsiyet tahmini yapılması amaçlandı. Çalışmada, 2020-2023 yılları arasında İzmir Bakırçay Üniversitesi Çiğli Eğitim ve Araştırma Hastanesi'nde Bilgisayarlı Tomografi (BT) Anjiyografi yapılan 15-95 yaş arası bireylerin görüntüleri retrospektif olarak incelendi. 500 kadın ve 500 erkek bireye ait 1000 görüntüleri açmak için RadiAnt DICOM Viewer (2023.1) programı kullanıldı. Görüntüler sadece os hyoideum kalacak şekilde temizlendi. Bir os hyoideum görüntüsünden anterior, posterior, dexter, sinister, superior, inferior ve superodexter olmak üzere toplam 7

yönden görüntü elde edildi. Böylece, kadınlar için 3500 ve erkekler için 3500 olmak üzere toplam 7000 görüntü elde edildi. Elde edilen görüntüler veri zenginleştirme yöntemi ile 10000'e tamamlandı. Veri zenginleştirme için yatay öteleme, %20 yükseklik kaydırma, %20 genişlik kaydırma, %20 döndürme ve yakınlaştırma yapıldı. Veri seti %80 eğitim seti, %10 doğrulama ve %10 test seti olarak bölündü. Derin öğrenme modelleri MobileNetV2, ResNet50, EfficientNet B0 ve EfficientNet V2B0 ile karşılaştırıldı. Cinsiyet tahminindeki doğruluk oranları MobileNetV2'de %91,7, ResNet50'de %92,7, EfficientNet B0'da %94,3 ve EfficientNet V2B0'da %95 olduğu görüldü. EfficientNet V2B0 modelinin erkeklerde özgüllüğü 0,94, duyarlılığı 0,95 ve F1 skoru 0,95; kadınlarda ise özgüllüğü 0,95, duyarlılığı 0,94 ve F1 skoru 0,94'tür. Os hyoideum'dan MobileNetV2, ResNet50, EfficientNet B0 ve EfficientNet V2B0 derin öğrenme yöntemleri kullanılarak yüksek oranda cinsiyet tahmini yapılmıştır. Çalışmada kullanılan veri sayısı arttıkça daha yüksek oranda başarı elde edildiği görülmüştür. Bu çalışma, güncel teknoloji kullanımını sağlayarak kullanılan yöntem ile özneliği azaltarak cinsiyet tahmini yapan uzmanlara destek olacaktır.

Anahtar Sözcükler : Os Hyoideum, Cinsiyet tahmini, EfficientNet V2B0, EfficientNet B0, ResNet50, MobileNetV2.

Bilim Kodu : 1005

ABSTRACT

Ph. D. Thesis

SEX ESTIMATION FROM COMPUTED TOMOGRAPHY IMAGES USING EFFICIENTNET DEEP LEARNING MODEL OF OS HYOIDEUM

Res. Assist. Rukiye Sümeyye BAKICI

**Karabük University
Institute of Graduate Programs
Department of Anatomy**

Thesis Advisor:

Assoc. Prof. Dr. Zülal ÖNER

June 2024, 55 pages

The hyoid bone is part of the viscerocranium and, unlike other bones in the skeletal system, it articulates only with muscles and ligaments. This bone is important in the functions of swallowing, speech, prevention of regurgitation, and airway maintenance. In forensic and bioarchaeological sciences, knowing the sex is a key factor in skeletal identification. In this study, aimed to estimate sex from hyoid bone utilizing the EfficientNet convolutional neural network architecture. In the study, images of individuals aged 15-95 who underwent Computed Tomography (CT) Angiography at İzmir Bakırçay University Çiğli Training and Research Hospital between 2020 and 2023 were retrospectively examined. RadiAnt DICOM Viewer (2023.1) was used to open images of 1000 individuals (500 Female and 500 Male).

In the opened images, it was cleaned so that only the hyoid bone remained. The opened images were purified so that only the hyoid bone remained. From a hyoid bone, images

were obtained from a total of 7 directions: front, back, up, down, right, left, and right-front. Thus, 3500 images were obtained for females and 3500 images for males, making a total of 7000 images. The images obtained were completed to 10000 with the data enrichment method. Horizontal translation, 20% height shift, 20% width shift, 20% rotation, and zooming were performed for data enrichment. The data set was divided into 10% test set, 10% validation and 80% training set. It was compared with deep learning models MobileNetV2, ResNet50, EfficientNet B0, and EfficientNet V2B0. Accuracy rates for sex estimation were 91.7% in MobileNetV2, 92.7% in ResNet50, 94.3% in EfficientNet B0 and 95% when using EfficientNet V2B0. The specificity of EfficientNet V2B0 model in males, specificity was 0.94, sensitivity was 0.95, and F1 score was 0.95; in females was 0.95, sensitivity was 0.94, F1 score was 0.94. In the hyoid bone MobileNetV2, ResNet50, EfficientNet B0 and EfficientNet V2B0 deep learning methods were used to estimate sex at a high rate. It was observed that a higher rate of success was achieved with the higher number of data used in the study. This study will support experts who make, sex estimation by reducing subjectivity with the method used by ensuring the use of up-to-date technology.

Key Words : Hyoid bone, Sex estimation, EfficientNet V2B0, EfficientNet B0, ResNet50, MobileNetV2.

Science Code : 1005

TEŞEKKÜR

Bu tez çalışmasının planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyen, lisansüstü eğitimime başladığım ilk günden itibaren doktora tezimin bitişine kadar geçen sürede bir büyüğüm olarak bana inanan, her aşamada beni destekleyip yüreklendiren, çalışmalarımı sabır ve titizlikle inceleyip yol gösteren danışmanım kıymetli hocam İzmir Bakırçay Üniversitesi Tıp Fakültesi Anatomi Anabilim Dalı Başkanı Sayın Doç. Dr. Zülal ÖNER'e, destekleriyle daima yardımcı olan kıymetli hocam Bolu Abant İzzet Baysal Üniversitesi Tıp Fakültesi Anatomi Anabilim Dalı Başkanı Sayın Prof. Dr. İbrahim KÜRTÜL'e, Radyoloji alanında desteklerini hiç esirgemeyen, doktora sürecimde bilgi ve destekleriyle çalışmalarına ışık tutan tez izleme kurulu üyesi değerli hocam İzmir Bakırçay Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı Öğretim Üyesi Sayın Doç. Dr. Serkan ÖNER'e, desteklerini daima hissettiren, doktora sürecimde ilgi, bilgi ve destekleriyle çalışmalarına ışık tutan tez izleme kurulu üyesi kıymetli hocam Karabük Üniversitesi Tıp Fakültesi Anatomi Anabilim Dalı Başkanı Sayın Doç. Dr. Şeyma TOY'a ve bu süreçte desteklerini hiç esirgemeyen değerli hocam Sinop Üniversitesi Bilgisayar Mühendisliği Bölümü Öğretim Üyesi Sayın Doktor Öğretim Üyesi Muhammet ÇAKMAK'a tüm kalbimle teşekkür ederim.

Hayatımın her alanında her türlü özveriyi, sabrı gösteren destekleriyle daima yanımda olan çok kıymetli aileme sonsuz teşekkür eder, sevgilerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xii
KISALTMALAR DİZİNİ	xiii
BÖLÜM 1	1
GİRİŞ	1
1.1. TEZİN AMACI	3
1.2. TEZİN ORGANİZASYONU.....	3
BÖLÜM 2	4
GENEL BİLGİLER.....	4
2.1. OS HYOİDEUM’UN ANATOMİSİ	4
2.2. OS HYOİDEUM’UN EMBRİYOLOJİK VE KEMİKLEŞME SÜRECİ.....	5
2.3. CİNSİYET TAHMİNİ.....	6
2.4. CİNSİYET TAHMİNİNDE KULLANILAN YÖNTEMLER.....	6
2.5. YAPAY ZEKÂ	7
2.6. DERİN ÖĞRENME	7
2.6.1. Sinir Ağı.....	8
2.6.2. Sinir Ağının Sınıflandırması	8
2.6.2.1. İleri Beslemeli Sinir Ağı (Feedforward Neural Network)	8
2.6.2.2. Tekrarlayan Sinir Ağı (Recurrent Neural Network).....	8
2.6.2.3. Radyal Temel Fonksiyonlu Sinir Ağı (Radial Basis Function Neural Network).....	9
2.6.2.4. Kohonen Kendi Kendini Düzenleyen Sinir Ağı (Kohonen Self Organizing Neural Network).....	9

	<u>Sayfa</u>
2.6.2.5. Modüler Sinir Ağı (Modular Neural Network).....	9
2.6.2.6. Evrişimli Sinir Ağı (Convolutional Neural Network-CNN).....	9
2.7. DERİN ÖĞRENME YÖNTEMLERİ	10
2.8. DERİN ÖĞRENME SİNİR AĞI MİMARİ MODELLERİ	10
2.8.1. MobileNetV2 Mimari Modeli.....	10
2.8.2. ResNet50.....	11
2.8.3. EfficientNet B0	11
2.8.4. EfficientNet V2B0	11
BÖLÜM 3	12
MATERYAL VE METOT	12
3.1. GÖRÜNTÜ POPÜLASYONU	12
3.2. KULLANILAN İSTATİSTİKSEL YÖNTEMLER.....	29
3.3. KULLANILAN DERİN ÖĞRENME YÖNTEMLERİ	29
BÖLÜM 4	30
BULGULAR.....	30
BÖLÜM 5	35
TARTIŞMA.....	35
BÖLÜM 6	41
SONUÇ VE ÖNERİLER	41
KAYNAKLAR.....	42
EK AÇIKLAMALAR A. ONAY YAZISI.....	53
ÖZGEÇMİŞ	55

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Os hyoideum'un anterior'dan görünüşü	4
Şekil 2.2. Os hyoideum'un posterior'dan görünüşü	5
Şekil 2.3. Os hyoideum'un superolateral'den görünüşü	5
Şekil 3.1. RadiAnt programında hastaların görüntülerinin açılması.....	13
Şekil 3.2. Görüntünün 3 boyutlu hale getirilmesi.	13
Şekil 3.3. Scalpel aracı.	14
Şekil 3.4. Diğer anatomik yapıların kesilerek sadece os hyoideum'un bırakılması. .	14
Şekil 3.5. Ekran alıntısı aracı ile dışa aktarım.....	15
Şekil 3.6. Ekran alıntısı aracı ile dışa .jpeg uzantılı kaydedilmesi.....	15
Şekil 3.7. Orijinal görüntüler (female=kadın, male=erkek).....	17
Şekil 3.8. Artırılmış görüntüler (female=kadın, male=erkek).....	23
Şekil 4.1. MobileNetV2 mimari modelindeki eğitim ve doğrulama setindeki a) kayıp veri, b) doğruluk oranı.	30
Şekil 4.2. MobileNetV2 mimari modelinde test setindeki hata (confusion) matrisi..	31
Şekil 4.3. ResNet50 mimari modelinde eğitim ve doğrulama setindeki a) kayıp veri, b) doğruluk oranı.	31
Şekil 4.4. ResNet50 mimari modelinde test setindeki hata (confusion) matrisi.	32
Şekil 4.5. EfficientNet B0 mimari modelinde eğitim ve doğrulama setindeki a) kayıp veri, b) doğruluk oranı.	32
Şekil 4.6. EfficientNet B0 mimari modelinde test setindeki hata (confusion) matrisi.	33
Şekil 4.7. EfficientNet V2B0 mimari modelinde eğitim ve doğrulama setindeki a) kayıp veri, b) doğruluk oranı.	33
Şekil 4.8. EfficientNet V2B0 mimari modelinde test setindeki hata (confusion) matrisi.	34

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 3.1. Görüntülerin eğitim, doğrulama ve test setlerine bölünmesi.....	16
Çizelge 4.1. Kullanılan mimari modellere ait performans ölçümleri.....	34

KISALTMALAR DİZİNİ

BT	: Bilgisayarlı Tomografi
CNN	: Convolutional Neural Network
GB	: Gigabyte
GHz	: Gigahertz
GPU	: Graphics Processing Unit
lig.	: Ligamentum
MRG	: Manyetik Rezonans Görüntüleme
m.	: Musculus
NLP	: Naturel Language Processing
proc.	: Processus
ResNet	: Residual neural network
vb.	: Ve benzeri

BÖLÜM 1

GİRİŞ

İnsan iskeleti her yıl yaklaşık %3 ile %10 arasında değişen bir oranda tazelenmektedir. Dolayısıyla kemikler doğumdan itibaren her on yılda bir tamamen yenilenme göstermektedir [1-3].

Uzun süre kayıp bireylerin yer aldığı vakalarda, ileri düzeyde çürümüş bedenlerde, geriye sadece insan parçalarının kaldığı doğal afetler veya kitlesel felaketlerde, savaş gibi durumlarda kimliği belirlemek önemlidir. Ayrıca adli kimlik tespiti yasal bir zorunluluktur [1, 4-6]. 18 Şubat 2003 Güney Kore’de Daegu metro faciasında hayatını kaybeden 192 kişiden 6 kişinin kimliği belirlenememiştir [7, 8]. 26 Aralık 2004 tarihinde Tayland tsunami faciası 9.1 şiddetindeki depremden sonra olmuştur. Toplam on üç ülkeden 280000 kişinin vefat etmesinden sonra sadece 1112 kişi kimliklendirilebilmiştir [8, 9]. Avustralya’nın Victoria eyaletinde 7 Şubat 2009’da meydana gelen orman yangını sonrasındaki süreçte elde edilen örneklerin bazıları çok küçük olduğu için kimliklendirme yapılamadığı bildirilmiştir [8, 10, 11]. Türkiye’deki 11 ili etkileyen 6 Şubat 2023 tarihinde Kahramanmaraş merkezli olan çevre ülkelerde de hissedilen büyük bir deprem olmuştur. Resmî rakamlara göre Türkiye’de en az 53537, Suriye’de ise en az 8476 kişi vefat etmiştir [12].

Adli kimlik tespiti tekniklerinde kimlik kartları inceleme, diş bulguları, dudak izleri, parmak izleri, ayak izleri gibi görsel kimlik belirleme ve DNA parmak izi bulunmaktadır [5]. Fiziksel antropoloji için vefat eden bireylerde antemortem dönemdeki görünümüne ait fotoğraf veya fiziksel bir tanımın yer aldığı arşivin bulunması önemlidir [13]. Ölen kişinin ibadetlerinden kaynaklı vücudunda meydana gelen dua işaretleri, yara izleri, dövmele, benler veya doğum lekeleri fiziksel tanımını kolaylaştırabilir [13, 14]. Buradan yola çıkılarak adli kimlik tespitinde eldeki bu bilgiler cesedin korunma durumu göz önünde bulundurularak değerlendirilebilir [13].

İskeletin elemanı olan kemikler ölümün üzerinden yıllar geçse de sağlam kalır. Böyle durumlar da iskeletten yani kemiklerden tanımlama yapılması gerekir. Kimlik belirlemede, cinsiyet tahmini birincil ölçüttür [1, 15].

İskelette yer alan kemikler, değişen oranda cinsel dimorfizm göstermektedir [16, 17]. DNA analizi ve parmak izi gibi yöntemlerin kullanılmadığı durumlarda antropometrik ölçümler ya da radyoantropometrik ölçümler kimlik tespitinde ve cinsiyet tahmininde kullanılmaktadır [16, 18]. Özellikle anatomiye dayalı yapılan metrik analizler cinsiyet tahmininde güvenilirlik oranının artmasını sağlayabilir [1].

Os hyoideum, klinik bilimlerde uyku apnesi, yutma fonksiyonu, hava yolunu değerlendirmek amacıyla çalışılmaktadır [19, 20]. Adli tıpta boyun travmalarında özellikle boğulma veya asılma vakalarında dikkatli bir şekilde incelenmektedir [21, 22]. Adli bilimlerde ve fiziksel antropolojide ise bireye ait sadece iskelet kalıntılarının bulunduğu olaylarda cinsiyet tahmininde kullanılmaktadır [23].

Yetişkin erkeklerde os hyoideum'a ait corpus ossis hyoidei, cornu majus ve cornu minus gibi uzunlukları ölçülen parametrelerin daha uzun olduğu bildirilmektedir. Kadınlarda ise şekil olarak genellikle kemiklerin daha geniş olduğu belirtilmektedir. Lakin cinsel dimorfizmin temelini, genişlik parametrelerindeki değişikliklerden ziyade toplam uzunluk parametrelerinde yattığı varsayılmaktadır [24]. Bu noktada cinsiyet tahmini kemiklerdeki gelişimsel değişikliklerin değerlendirilmesiyle başarılabılır [22].

Son yıllarda yapay zekâya dayalı yöntemler, tıpta hastalık tahmininde ve biyo-arkeolojik çalışmalarda yaygın olarak kullanılmaktadır [25]. Yapay zekâ yöntemleri, cinsiyet tahmini yöntemlerine tekrarlanabilir ve objektif bir çözüm sunmaktadır [26]. Alanda çalışan adli tıp, arkeoloji, antropoloji uzmanların performanslarının artmasına katkıda bulunmakla birlikte hataların azaltılmasına da yardımcı olur [27]. Yapay zekânın etkin kullanımının arkeoloji, fiziksel antropoloji ve adli sorunlara yardımcı olup olamayacağı ya da bu alanda kullanılan ve iyi bilinen çözümlerin yerini alıp alamayacağını araştırmak önemlidir.

1.1. TEZİN AMACI

Os hyoideum'da cinsiyet tahmini yapılırken derin öğrenme yöntemlerinden MobileNetV2, ResNet50, EfficientNet B0 ve EfficientNet V2B0 modelleriyle doğruluk oranları karşılaştırılması amaçlandı. Böylece bu kemikte bulunan cinsel dimorfizm, derin öğrenme mimari modelleri kullanıldığındaki cinsiyet tahminindeki başarısı ortaya konacaktır.

1.2. TEZİN ORGANİZASYONU


Tezin üçüncü bölümünde materyal ve metot, dördüncü bölümünde bulgular, beşinci bölümünde tartışma ve son bölümünde sonuç ve öneriler yer almaktadır.

BÖLÜM 2

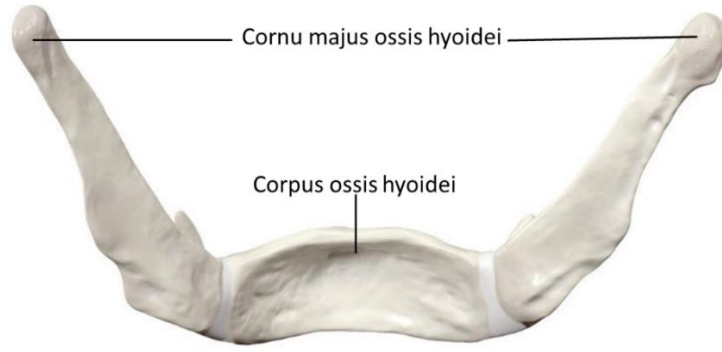
GENEL BİLGİLER

2.1. OS HYOİDEUM'UN ANATOMİSİ

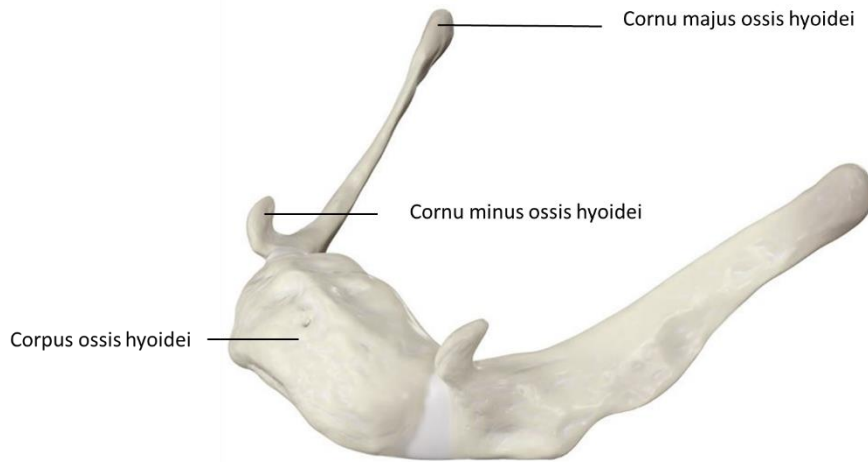
Hyoid, dilin altında bulunan, yumuşak dokular aracılığı ile konumunu koruyan dil kemiği anlamına gelmektedir [28, 29]. Os hyoideum, boynun ön tarafında, mandibula'nın alt kenarı seviyesinde, larynx'in üst kısmında yer alıp yere paralel seyreder. Erişkinde üçüncü vertebra cervicalis seviyesinde yer almaktadır. Şekli "U" harfi ya da at nalına benzeyip açıklığı arkaya doğru bakmaktadır. Os hyoideum, nefes alma ve yutma koordinasyonunda önemlidir. Bu kemiğin bir gövdesi ve dört boynuzu bulunmaktadır. Orta kısmında yer alan gövdesine corpus ossis hyoidei, kısa olan boynuzuna cornu minus, uzun olan boynuzuna ise cornu majus denir (Şekil 2.1-2.3). Cornu majus, corpus'tan bilateral olarak arkaya doğru uzanan kısımlardır. Cornu minus'lar ise corpus ile cornu majus'un birleştiği kısımlardan yukarı ve arkaya doğru uzanmaktadırlar [1, 30-32].



Şekil 2.1. Os hyoideum'un anterior'dan görünüşü [33].



Şekil 2.2. Os hyoideum'un posterior'dan görünüşü [33].



Şekil 2.3. Os hyoideum'un superolateral'den görünüşü [33].

Os hyoideum, vücuttaki hiçbir kemikle bağlantısı olmayan tek kemiktir [30, 34]. Ancak cornu minus ile processus (proc.) styloideus arasında ligamentum (lig.) stylohyoideum uzanmaktadır. Corpus'a ise musculus (m.) sternohyoideus, m. mylohyoideus, m. geniohyoideus ve m. omohyoideus kasları insertio yapar. Cornu majus'a da m. thyrohyoideus, m. stylohyoideus, m. hyoglossus, m. digastricus venter anterior ve m. constrictor pharyngis medius kasları sonlanmaktadır [31].

2.2. OS HYOİDEUM'UN EMBRİYOLOJİK VE KEMİKLEŞME SÜRECİ

İkinci pharyngeal arcus (arcus pharyngealis secundus) ve üçüncü pharyngeal arcus'lar (arcus pharyngealis tertius) os hyoideum'un oluşumunda etkilidir. Arcus pharyngealis secundus'un ventral ucu kemikleşerek os hyoideum'un gövdesinin üst parçası ile

cornu minus'ları yapar. Arcus pharyngealis tertius'un ventral parçası kemikleşerek os hyoideum'un gövdesinin alt kısmı ile cornu majus'ları yapar [35, 36].

Os hyoideum 6 merkezden kemikleşme sürecine başlar. İki tanesi corpus'u, 4'ü de cornu'larında kemikleşir. İntrauterin dönemin son zamanlarında cornu majus'da, daha sonrasında corpus hyoideum'da kemikleşme süreci başlarken ve cornu minus da ise 1-2 yaşlarında kemikleşme başlar [30].

2.3. CİNSİYET TAHMİNİ

Türün hayatta kalmasını, iki ayrı bileşen kümesinin yeteneklerinin nesillere aktarılmasını sağlayan yapıya biyolojik cinsiyet denir [37]. Çağdaş toplumlarda yasal-tıbbi bağlamda veya geçmiş toplumlarda anonim iskelet kalıntıları belirlemek için biyolojik cinsiyet tahmini yapmak önem arz etmektedir [38]. Cinsiyet tahmini antropoloji, arkeoloji, adli ve fiziksel antropoloji, adli tıp alanlarında kullanılmaktadır [39, 40]. Bu alanlarda düşük maliyetli metotlarla insanı doğru tanımlanmasını sağlayan anatomik bilgilerle multidisipliner çalışmayı gerekli kılmaktadır [1].

Cinsel dimorfizm, bir popülasyon veya bir türün eşeyleri arasında görülen farklılıkların bütünü olarak adlandırılmaktadır. Popülasyon genetiği, cinsel dimorfizm oranını artıran en değerli faktördür. Ayrıca mekanik stres, beslenme, yaşam tarzı ile ilgili seküler değişiklikler, coğrafi ve sosyal izolasyon gibi çevresel faktörler bu oranı etkileyen diğer faktörler arasında yer almaktadır [39]. İnsan iskeletinde erkeklerin kadınlardan ayrılmasını testosteron hormonu sağlamaktadır [39]. Mikroanatomik olarak incelendiğinde ise Havers kanalı alanlarının erkeklere ait kemik örneklerinde kadınlara göre dikkate değer derecede daha az olduğu belirtilmiştir [41]. Dolayısıyla cinsiyet tahmini kemiklerde görülen gelişimsel değişimlerin değerlendirilmesiyle ortaya konabilir [22].

2.4. CİNSİYET TAHMİNİNDE KULLANILAN YÖNTEMLER

Cinsiyet tahmin yöntemleri klasik olarak morfoskopik ve metrik yöntemler şeklinde incelenmektedir [38]. Moleküler yöntemlerde ise genomik, epigenetik, proteomik ve

mikrobiyomik analizler yer almaktadır [4, 38]. Morfoskopik yöntemler öznelidir. Dolayısıyla karar verirken taraflı yani gözlemciye bağımlı olması sebebiyle daha az güvenilirdir. Metrik yaklaşımlar ise yorumlanabilir ve daha güvenilirdir. Her iki yöntemde popülasyona özgü etkenlerden oldukça etkilenmektedir [38]. Ancak bu osteolojik yöntemlerin kullanım alanını mezarlıklarda ikinci kez gömme veya ölüleri yakma gibi durumlar sınırlandırmaktadır [42].

Adli vakalarda cinsiyet tahmini yapılırken Röntgen, Bilgisayarlı Tomografi (BT) veya Manyetik Rezonans Görüntüleme (MRG) vb. görüntüleme yöntemlerinin kullanımı uzmanların patojenlere doğrudan maruz kalmasını önler [43-45]. Bu görüntüleme yöntemleri geleneksel otopsiye alternatif bir yöntem olarak kullanılabilir [43, 46]. Adli görüntüleme, geleneksel yöntemlerin kullanıldığı araştırmalardaki çıkan sonuçları destekleyen nitelikte objektif veriler sağlayabilir [43].

2.5. YAPAY ZEKÂ

Yapay zekâ, matematiksel bir biçimde insan öğrenme sürecinin modellenmesidir [47]. Son yıllarda sağlık alanında yapay zekânın kullanımının artmasıyla beraber klinik karar vermede teşhis, tedavi sürecinde yardımcı olma ve gizlenen klinik açıdan anlamlı bilgileri ortaya çıkarabilir. Ayrıca yapay zekâ sağlık risk uyarısında ve sağlık sonucu tahmininde doğru çıkarımlar elde edebilmek için yararlı bilgiler ortaya koyar [48].

2.6. DERİN ÖĞRENME

Derin öğrenme, klasik sinir ağının tekniğine kıyasla çok daha fazla sinir ağına sahip olduğu modern uzantısıdır. Derin öğrenme, karmaşık ve yüksek hacimli veri kaynakları arasındaki doğrusal olmayan kompleks kalıpları ve ilişkileri keşfedebilmektedir [48-50]. Makine öğrenmenin bir alt kümesi olan derin öğrenme, derin sinir ağlarının eğitilmesine odaklanmaktadır [50].

Derin öğrenme katman yapısı; veri giriş işleminin yapıldığı girdi katmanı olarak adlandırılan ilk katmanla başlamaktadır. Ardından normalizasyon işlemi yapılarak Evrişimsel (Convolution), Aktivasyon (ReLU), Havuzlama (Pooling), Ezberleme

(Dropout), Tam Bağlantı (Fullconnected) ve Sonuçlandırma katmanları takip edilmektedir [51-54].

2.6.1. Sinir Ağı

Sinir ağı, insanın beyin yapısından ilham alan ve sinir sistemine benzeyen makine öğrenme tekniğidir [55]. Giriş katmanı, gizli katman ve çıkış katmanından oluşmaktadır [55, 56]. Bir sinir ağının ilk katmanı girdi katmanı olup dış dünya ile doğrudan etkileşim halindedir. İkinci katman ise hesaplamanın sağlandığı fonksiyona göre yapıldığı gizli katmandır. Son katman ise çıktının elde edildiği çıkış katmanıdır [56, 57]. Amaç, girdi ile çıktı verilerini kullanarak ağırlıkları tahmin ederek sonuç ve tahmin arasındaki ortalama hatayı en aza indirmektir [48]. Sinir ağları, kümeleme, sınıflandırma, örüntü tanıma, regresyon, doğal dil işleme (Naturel Language Processing-NLP), tahmine dayalı analiz, boyut azaltma ve bilgisayarla görme vb. gibi problemlerde kullanılabilir [55].

2.6.2. Sinir Ağının Sınıflandırması

2.6.2.1. İleri Beslemeli Sinir Ağı (Feedforward Neural Network)

İleri beslemeli sinir ağında bilgi, giriş katmanından çıkış katmanına yalnızca bir yönde akarken herhangi bir döngü veya geri bildirim oluşturmamaktadır. Bu ağın genellikle tanıma, sınıflandırma ve örüntü oluşturmak amacıyla kullanımı yaygındır [55, 58, 59].

2.6.2.2. Tekrarlayan Sinir Ağı (Recurrent Neural Network)

Bu sinir ağında ileri beslemeli sinir ağının aksine işlem birimleri bir döngü oluşturur. Bir katmanın çıktısı, ağdaki tek katman olan diğer katmanın girdisi şeklindedir. Böylece katmanın çıktısı, bir geri besleme döngüsü oluşturarak kendi başına girdi haline gelir. Bu durum ağın önceki durumlar hakkında belleğe sahip olmasını ve bu belleği mevcut çıktı için kullanmasını sağlar. Tekrarlayan sinir ağının, sıralı girdilerin olduğu görevleri içeren doğal dil işleme ve konuşma gibi alanlarda kullanılması daha uygun bulunmaktadır [50, 55, 58].

2.6.2.3. Radyal Temel Fonksiyonlu Sinir Ağı (Radial Basis Function Neural Network)

Fonksiyon yaklaşımı teorisinden üretilmiştir. Giriş, gizli ve çıkış olmak üzere üç katmandan oluşum göstermektedir. Gizli katmanda bir radyal temel fonksiyonu yer almaktadır. Bu ağ sınıflandırma, zaman serisinin tahmin problemleri ve fonksiyon yaklaşımları gibi durumlarda kullanılır [55, 60, 61].

2.6.2.4. Kohonen Kendi Kendini Düzenleyen Sinir Ağı (Kohonen Self Organizing Neural Network)

Kohonen'in kendi kendini organize eden sinir ağı, ağ modeli giriş verilerine göre denetimsiz öğrenmeyi kullanarak kendisi düzenler. Birbiriyle tamamen bağlantılı iki katmandan oluşur. Bu katmanlar, giriş ve iki boyutlu bir ızgara olarak düzenlenmiş çıkış katmanlarıdır [55, 62].

2.6.2.5. Modüler Sinir Ağı (Modular Neural Network)

Büyük ağı, bağımsız olan daha küçük sinir ağı modüllerine bölen ağıdır. Daha küçük ağlar tüm ağın tek bir çıktının parçası olarak birleştirilen, belirli görevleri yerine getirir [55].

2.6.2.6. Evrişimli Sinir Ağı (Convolutional Neural Network-CNN)

CNN mimarisi görsel algıdan esinlenilerek yapılmış, zamansal ve mekânsal bağıntıları etkili bir şekilde yakalamak, görüntü girdilerini analiz etmek, görüntüler içindeki nesnelere tanımak için tasarlanmış özel bir sinir ağı türüdür [50, 63, 64]. Normal sinir ağlarına çok benzeyen CNN, döngüsel olmayan bir nöron topluluğu olarak görselleştirilmektedir [65]. Bu derin sinir ağı Neocognitron'un ağ yapısına dayanıp görüntüleri girdi şeklinde alarak bilgisayarlı görmede kullanılmaktadır [66-68]. CNN'den görüntü oluşturma, görüntü sınıflandırma ve tıbbi uygulamalarda daha sık faydalanılmaktadır [48, 69].

CNN'in ilk katmanı evrişim katmanıdır ve belirli boyuttaki bir filtreyi görüntü üzerinde hareket ettirerek, bir özellik haritası oluşturmak için birçok kez çalıştırılır. Bu aşamalar görüntünün özelliklerini ortaya çıkarmak için uygulanır [70].

2.7. DERİN ÖĞRENME YÖNTEMLERİ

Derin öğrenme popüler olarak CNN, Seyrek Otomatik Kodyacılar (Sparse Autocoders), Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines) ve Uzun Kısa-Sürelili Bellek (Long Short- Term Memory) yöntemleriyle uygulanır [50, 55].

Sinir ağı modelleri ayırmacı model ve üretken model olarak iki farklı kategoriye ayrılır. Ayırmacı model (Discriminative), verilerin girdi katmanından gizli katmana geçtikten sonra çıktığı katmanına ulaştığı, aşağıdan yukarı doğru olan bir yaklaşımdır. Üretken modeller (Generative) ise veri akışı yukarıdan aşağıya olup ters yöndedir [55].

2.8. DERİN ÖĞRENME SİNİR AĞI MİMARİ MODELLERİ

Derin öğrenme sinir ağı mimarilerinin amacı daha küçük modeller kullanarak daha yüksek verimli yaklaşımları ortaya çıkarmaktır [49].

2.8.1. MobileNetV2 Mimari Modeli

MobileNet modeli, 2017 yılında önerilmiş olup tam evrişim olan ilk katman dışında derinlemesine ayrılabilir evrişimler (Depthwise Separable Convolution) üzerine kurulmuştur. Mimari yapı olarak toplamda 28 katmana sahiptir. MobileNetV2 mimari yapısı önceki versiyon MobileNetV1'e dayanmaktadır. Bu mimari modelde Doğrusal Darboğazlar (Linear Bottlenecks), doğrusal olmayan katmanlardaki bilgilerin kaybolma problemini iyileştirmekle birlikte bilgiyi korumak için Ters Çevrilmiş Artıklar (Inverted Residuals Structure) adlı yapıyı sunmaktadır [71-73]. Bu mimari model cep telefonlarında da kullanılabilir [74].

2.8.2. ResNet50

Residual Neural Network kısaca ResNet olarak adlandırılır [75, 76]. İlk kez 2015 yılında pratikliği ve basitliği sebebiyle önerilmiştir [77, 78]. ResNet50, 48 evrişim katmanı, bir maksimum havuzlama katmanı ve bir ortalama havuzlama katmanı olmak üzere toplam 50 katman residüel ağdan oluşan bir CNN mimarisidir. Çoklu katmanlarla çalışılan sinir ağları, daha az katmanlı modellere göre eğitim hatası üretme eğilimindedir. Bu model, kısayol bağlantıları eklenmesine, artık işlevlerin kullanılması ile derin sinir ağlarında olan yığılmış katmanlardaki eğitim hatalarının azaltılmasına imkân sağlamaktadır [70, 79]. Kullanım alanı olarak yaş ve cinsiyet tanımlamasında önerilmektedir [80].

2.8.3. EfficientNet B0

EfficientNet modeli, B0'dan başlayarak B8'e kadar şu anda bilinen dokuz modelden oluşmaktadır. Bu şekilde ilerlerken her modelden sonra gelen yeni model daha fazla parametreye ve daha yüksek doğruluk oranına sahip değişkenlere bakmaktadır. Bu mimari yöntem hesaplama gücü ve zamandan tasarruf sağlamak için transfer öğrenimi kullanmaktadır. Genişlik, derinlik ve çözünürlükte akıllı bir ölçeklendirme kullanarak son teknoloji modellerine göre çok daha yüksek oranda doğruluk oranı sağlamaktadır [49, 81, 82].

2.8.4. EfficientNet V2B0

EfficientNetV2 mimari modeli daha önceki modellere göre daha iyi parametre verimliliği ve daha hızlı eğitim hızına sahip bir evrişimli sinir ağıdır. Aşamalı öğrenme (progressive learning) ile önceki modellere göre daha iyi performans gösterebilir. Ayrıca son teknoloji modellerine göre daha kısa sürede eğitilebildiği görülmüştür [82-84].

BÖLÜM 3


MATERYAL VE METOT

Söz konusu olan bu çalışma için 05.04.2023 tarihli 970 protokol numarasıyla İzmir Bakırçay Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Yerel Etik Kurulu'ndan onay alındı.


3.1. GÖRÜNTÜ POPÜLASYONU

Çalışmada retrospektif olarak 2020-2023 yılları arasında BT Angiografi çekilmiş 15-95 yaş arasındaki bireylere ait görüntülere bakıldı. Çalışmaya dahil edilme kriteri olarak os hyoideum'un tam kemik yapısının bulunduğu görüntüler alındı. Dahil edilmeme kriterleri olarak osteoporotik os hyoideum ve proc. styloideus ile eklemlenme gösteren görüntüler çalışma dışı bırakıldı. Bu şartları sağlayan toplamda 1000 BT görüntüsü alındı. Her bir görüntü üzerinde anterior, posterior, dexter, sinister, superior, inferior ve supero-dexter şeklinde 7 yönden çalışıldı. 1000 adet os hyoideum'dan 7000 görüntü elde edildi.


Tüm görüntüleri açmak için RadiAnt DICOM Viewer (2023.1) programı kullanıldı (Şekil 3.1). Görüntüler *3D Volume Rendering* butonu ile 3 boyutlu hale getirildi (Şekil 3.2). Açılan pencerede *Scalpel* aracı kullanılarak sadece os hyoideum kalıncaya kadar görüntüde yer alan diğer yapılar kesilerek görüntü temizlendi (Şekil 3.3-3.4). Bu işlemde sonra os hyoideum'a yön ayarlaması yapıldı. Ardından *Ekran Alıntısı Aracı* ile görüntüler kesilerek resim (.jpeg) formatında dışa aktarıldı (Şekil 3.5-3.6). Aktarılan görüntüler için dosyalama işlemi önce cinsiyete sonra da yönlerine göre oluşturuldu. Hastaların isim ve yaşı Microsoft Excel'e yazıldı.




Şekil 3.1. RadiAnt programında hastaların görüntülerinin açılması.




Şekil 3.2. Görüntünün 3 boyutlu hale getirilmesi.



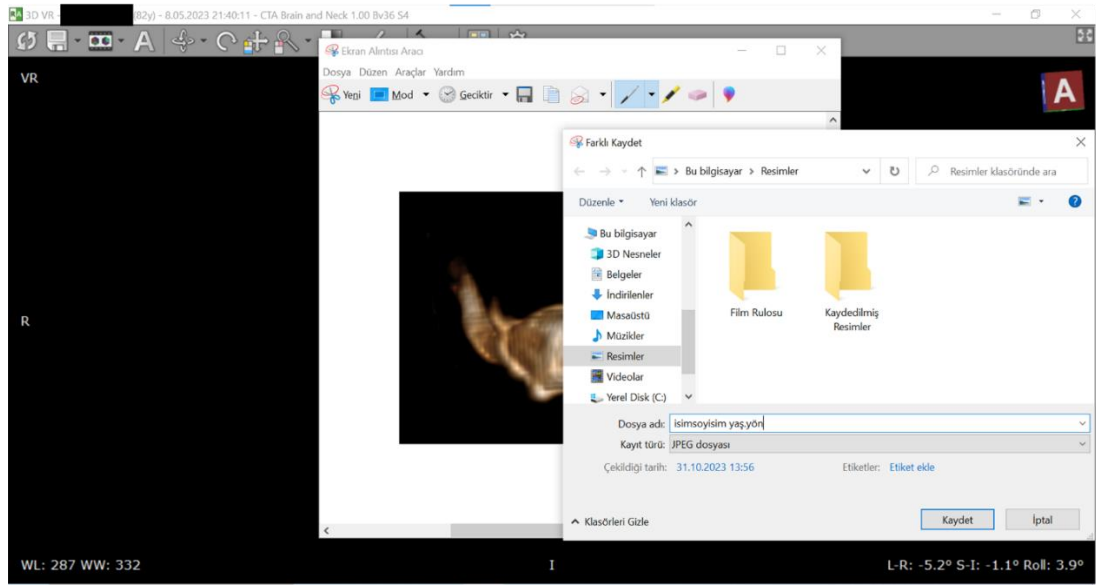
Şekil 3.3. Scalpel aracı.



Şekil 3.4. Diğer anatomik yapıların kesilerek sadece os hyoideum'un bırakılması.



Şekil 3.5. Ekran alıntısı aracı ile dışa aktarım.




Şekil 3.6. Ekran alıntısı aracı ile dışa .jpeg uzantılı kaydedilmesi.


Erkek ve kadın şeklinde isimlendirilen klasörlere 500 adet görüntü aktarıldı. Kadınlara ait yedi yönden alınan toplam 3500 görüntü, veri zenginleştirme yöntemi ile 5000'e tamamlandı (Şekil 3.7-3.8). Bu işlem aynı şekilde erkeklere ait görüntüler üzerinde de yapıldı. Veri zenginleştirme için %20 rotasyon, %20 genişlik kaydırma, %20 yükseklik kaydırma, horizontal çevirme ve yakınlaştırma yapıldı. Veri seti %80 eğitim seti, %10 doğrulama ve %10 test seti olarak ayrıldı (Çizelge 3.1).

Çizelge 3.1. Görüntülerin eğitim, doğrulama ve test setlerine bölünmesi.


	Total veri	Eğitim Seti (80%)	Doğrulama Seti (%10)	Test Seti (%10)
Orjinal veri seti	3500+3500=7000	-	-	-
Genişlemiş veri seti	10000	8000	1000	1000




Şekil 3.7. Orijinal görüntüler (female=kadın, male=erkek).




Şekil 3.7. (devam ediyor).



Şekil 3.7. (devam ediyor).




Şekil 3.7. (devam ediyor).




Şekil 3.7. (devam ediyor).




Şekil 3.7. (devam ediyor).




Şekil 3.8. Artırılmış görüntüler (female=kadın, male=erkek).




Şekil 3.8. (devam ediyor).




Şekil 3.8. (devam ediyor).



Şekil 3.8. (devam ediyor).



Şekil 3.8. (devam ediyor).



Şekil 3.8. (devam ediyor).

3.2. KULLANILAN İSTATİSTİKSEL YÖNTEMLER

Çalışmada Minitab 17 programı istatistiksel analizler için kullanıldı. Normal dağılıma uygunluğu Anderson-Darling testi ile yapıldı. Normal dağılım göstermediğinden Mann-Whitney U testi kullanıldı. $p < 0,05$ istatistiksel olarak anlamlı kabul edildi.

3.3. KULLANILAN DERİN ÖĞRENME YÖNTEMLERİ

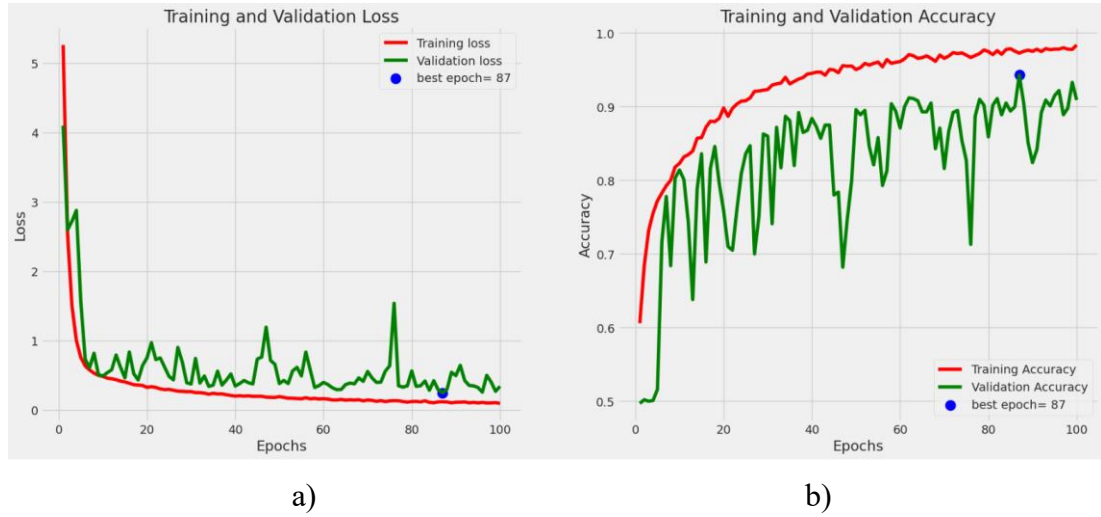
Çalışmada derin öğrenme modelleri, Google bulut ortamında Grafik işlem birimi (Graphics Processing Unit-GPU) destekli bir sistem kullanılarak eğitildi. Eğitim Tesla T4 GPU ve 16 GB Random Access Memory (RAM)'e sahip 2,20 GHz Intel Xeon CPU üzerinde gerçekleştirildi. Çalışma Keras 2.3.1 ve Tensorflow 1.4 kütüphaneleri ve Python 3 programlama dili kullanılarak yazıldı. MobileNetV2, ResNet50, EfficientNet B0, EfficientNet V2B0 yöntemleri kullanılarak os hyoideum'a ait görüntülerden cinsiyet tahmin oranları hesaplandı.

BÖLÜM 4


BULGULAR

500 kadın ve 500 erkek toplamda 1000 kişiye ait görüntüler çalışmaya dahil edildi. Kadınların yaş ortalaması $52,24 \pm 17,94$, erkeklerin yaş ortalaması ise $48,82 \pm 18,48$ 'dir. Erkek ve kadın yaşlarının normal dağılım göstermediği belirlendi ($p < 0,05$). Kadınların ortanca değeri 52 (16-94) yaş, erkeklerin ise 50 (15-94) yaş olduğu ve farkın kadınlar lehine istatistiksel olarak anlamlı olduğu saptandı.

MobileNetV2 mimari modeli kullanıldığında test setindeki 1000 veriden 83 veri tahmininde hata yaptığı, sonucunda ise 0,917 oranında doğruluk saptandı. Test setindeki doğruluk oranı ve kayıp veriyi Şekil 4.1'te gösterilmektedir. Modele ait hata (confusion) matrisi Şekil 4.2.'de gösterilmektedir.




Şekil 4.1. MobileNetV2 mimari modelindeki eğitim ve doğrulama setindeki a) kayıp veri, b) doğruluk oranı.




Şekil 4.2. MobileNetV2 mimari modelinde test setindeki hata (confusion) matrisi.

ResNet50 mimari modeli kullanıldığında test setinde 1000 veriden 73 hata ile 0,927 oranında doğruluk görüldü. Test setindeki doğruluk oranı ve kayıp veriyi Şekil 4.3'te, Şekil 4.4'te modele ait hata (confusion) matrisi gösterilmektedir.

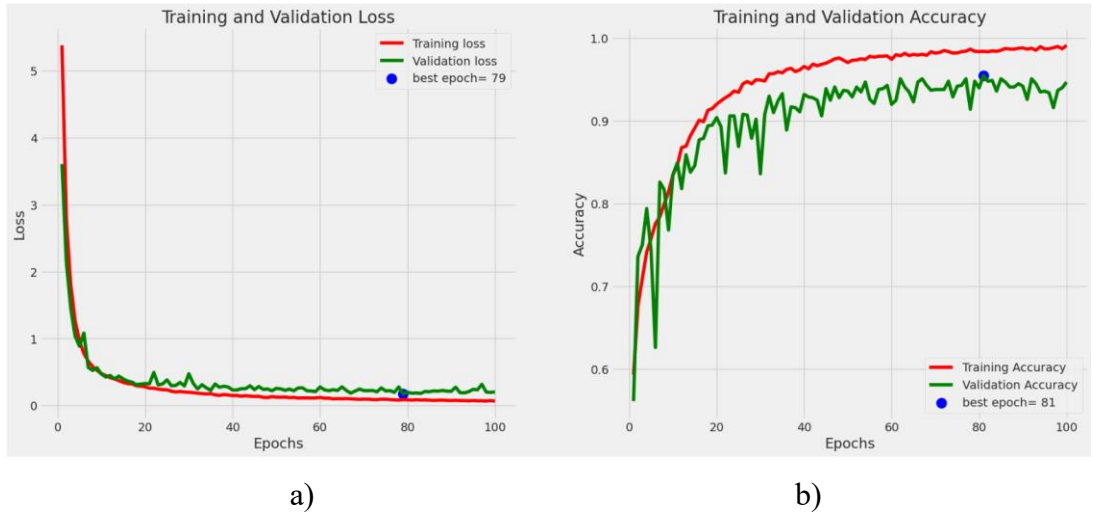


Şekil 4.3. ResNet50 mimari modelinde eğitim ve doğrulama setindeki a) kayıp veri, b) doğruluk oranı.




Şekil 4.4. ResNet50 mimari modelinde test setindeki hata (confusion) matrisi.

EfficientNet B0 mimari modelinde test setinde 1000 veriden 57 hata ile 0,943 oranında doğruluk görüldü. Test setindeki doğruluk oranı ve kayıp veriyi Şekil 4.5'te, Şekil 4.6'da modele ait hata (confusion) matrisi gösterilmektedir.

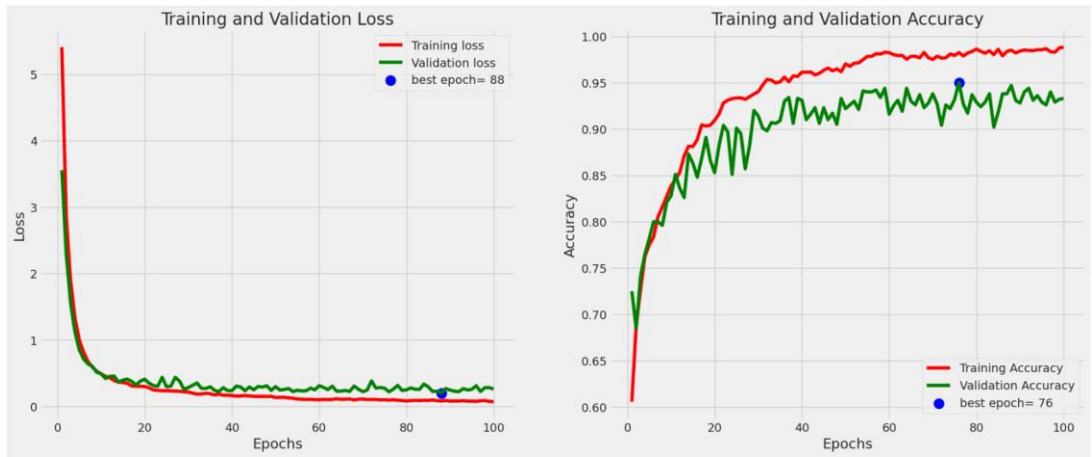


Şekil 4.5. EfficientNet B0 mimari modelinde eğitim ve doğrulama setindeki a) kayıp veri, b) doğruluk oranı.



Şekil 4.6. EfficientNet B0 mimari modelinde test setindeki hata (confusion) matrisi.

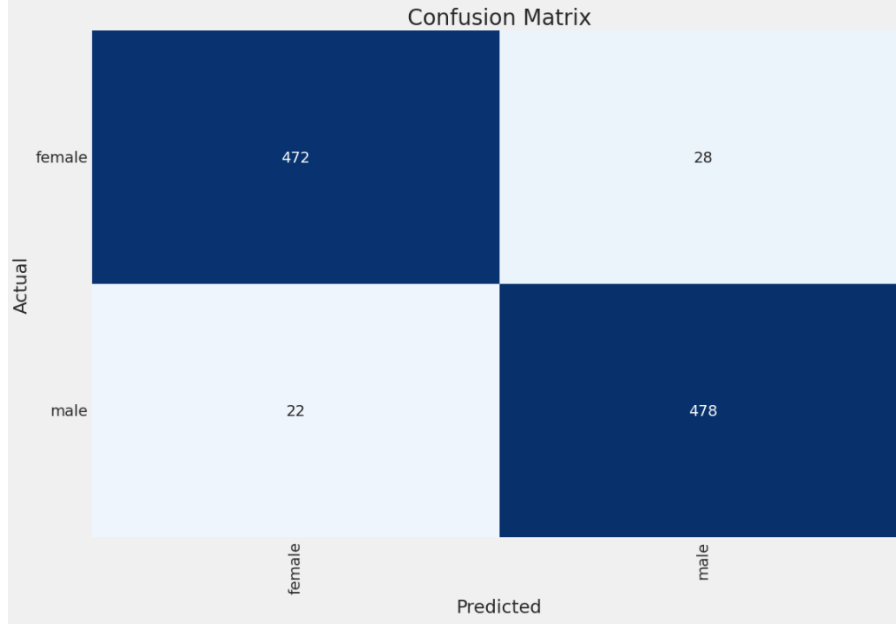
EfficientNet V2B0 mimari modelinde test setinde 1000 veriden 50 hata ile 0,950 oranında doğruluk görüldü. Eğitim ve doğrulama setindeki doğruluk oranını Şekil 4.7’de modele ait hata (confusion) matrisi Şekil 4.8’de gösterilmektedir.



a)

b)

Şekil 4.7. EfficientNet V2B0 mimari modelinde eğitim ve doğrulama setindeki a) kayıp veri, b) doğruluk oranı.



Şekil 4.8. EfficientNet V2B0 mimari modelinde test setindeki hata (confusion) matrisi.

MobileNetV2, ResNet50, EfficientNet B0 ve EfficientNet V2B0 kullanılan mimari modellere ait spesifite, sensitivite, F1 skor ve doğruluk oranları Çizelge 4.1’de verildi.

Çizelge 4.1. Kullanılan mimari modellere ait performans ölçümleri.

Mimari Model		Spesifite (Spe)	Sensitivite (Sen)	F1 Skor	Doğruluk oranı
MobileNetV2	Kadın	0,929	0,902	0,915	0,917
	Erkek	0,904	0,932	0,918	
	Makro ortalama	0,917	0,917	0,917	
	Ağırlıklı ortalama	0,917	0,917	0,917	
ResNet50	Kadın	0,913	0,944	0,928	0,927
	Erkek	0,942	0,910	0,925	
	Makro ortalama	0,927	0,927	0,927	
	Ağırlıklı ortalama	0,927	0,927	0,927	
EfficientNet B0	Kadın	0,921	0,968	0,944	0,943
	Erkek	0,966	0,918	0,941	
	Makro ortalama	0,944	0,943	0,943	
	Ağırlıklı ortalama	0,944	0,943	0,943	
EfficientNet V2B0	Kadın	0,955	0,944	0,949	0,950
	Erkek	0,944	0,956	0,950	
	Makro ortalama	0,950	0,950	0,950	
	Ağırlıklı ortalama	0,950	0,950	0,950	

BÖLÜM 5

TARTIŞMA

Parçalanmış bedenlerin yer aldığı adli vakalarda, toplu doğal ya da insan kaynaklı olan felaketlerde ya da paleoantropolojik ve arkeolojik kazılar sırasında iskelet elemanları bulunabilir. Parçalı bedenlerin bulunduğu olayların çözümlenmesi için çeşitli kemiklerden cinsiyet tahmini yapmak gerekmektedir [85-87]. Bu çalışma buna benzer vakaların yer aldığı durumlarda elde edilen os hyoideum'dan cinsiyet tahmini sonuçlarına ulaşmak maksadıyla yapıldı.

Os hyoideum, adli tıpta travmatik boyun yaralanmalarında sıkça incelenen bir kemiktir [21, 22]. Ayrıca bu kemiğin soliter [88], kırılmaya ve parçalanmaya çok izin vermeyen bir kemik olması [89], RadiAnt programı üzerinde DICOM görüntülerinin temizlenmesi sırasında çalışmaya kolaylık sağladı. Bu noktalar göz önüne alındığında söz konusu olan çalışma için os hyoideum tercih edildi.

Literatürde yer alan os hyoideum'a ait doğrudan kemik üzerinden yapılan ölçüm çalışmaları [21, 90], kemiklere ait fotoğraflar üzerinden yapılan çalışmalar [22, 88] ya da BT görüntüleri üzerinden yapılan çalışmalar [91, 92] ile çeşitli yöntemlerle cinsiyet tahmini yapıldığı görülmüştür. Bu çalışmada ise cinsiyet tahmini için BT görüntülerinden elde edilen .jpeg resim görüntüleriyle MobileNetV2, ResNet50, EfficientNet B0 ve EfficientNet V2B0 derin öğrenme mimari modelleri kullanıldı. Böylece os hyoideum üzerinde yeni bir yöntem uygulandı.

Omurga gibi kemik yapılar BT görüntülerinde, MRG'de ise disk hernisi gibi yumuşak dokular daha iyi ayırt edilir [93, 94]. Ayrıca arkeolojik veri setleri ile sınırlı sayıda kemiklere ulaşılırken, radyolojik görüntüleme sonucu elde edilen özellikle BT görüntüleri ile büyük veri setlerine daha güvenilir bir şekilde ulaşılabilir [91]. Dolayısıyla çalışmada BT görüntüleme yöntemi kullanıldı.

Hint Bengal popülasyonunda 50 yetişkin bireye ait kuru os hyoideum'la yapılan diskriminant fonksiyon analizi sonucu cinsiyet tahminindeki doğruluk %90 olarak belirtilmiştir [95]. Koreli 85 kadavradan (52 erkek, 33 kadın) elde edilen os hyoideum'a ait fotoğraflar üzerinden yapılan ölçümlerde diskriminant fonksiyonuyla cinsiyet tahmin oranı %88,2 olarak elde edilmiştir [88]. Türk toplumunda 85 kadavradan alınmış os hyoideum'dan diskriminant fonksiyonu ile cinsiyet tahmini hesaplanmış, doğruluk oranı erkeklerde %92,5 ve kadınlarda %78,1 olarak sınıflandırılmıştır [22]. Bu çalışmada ise ResNet50 derin öğrenme yöntemi kullanılarak cinsiyet tahminindeki doğruluk oranı %92,7 olarak elde edildi.

Literatürdeki bir çalışma Avrupa ve Çek kökenli adli tıp otopsilerinden elde edilmiş 298 os hyoideum'la cinsiyet tahminindeki uygun olan modeli bulmak amacıyla yapılmıştır. Sonucunda, linear diskriminant fonksiyon analizi oranı %92,4, sembolik regresyon modeli olan logistik regresyon modeli başarı oranı %96,43, geometrik morfometrik yöntemiyle başarı oranı %85,3 şeklinde bildirilmiştir [24]. Hindistan'daki bir çalışmada 100 os hyoideum kullanılarak yapılan diskriminant analizi sonucunda cinsiyet tahmin oranı %62 olarak aktarılmıştır [96]. Suganchander Hindistan'da 200 kuru os hyoideum üzerinde kumpasla ölçüm yaptığı çalışmasında, cinsiyet tahminini diskriminant analizi ile değerlendirdiğinde oranını %80,2 olarak saptamıştır [97]. Bu çalışmada bir CNN modeli olan EfficientNet B0 kullanılarak elde edilen cinsiyet tahminindeki doğruluk oranı %94,3 olarak saptandı. Çalışmalar arasındaki cinsiyet tahmin oranı farkının kullanılan model farkından ve çevresel faktörlerden kaynaklandığı kanaatindeyiz.

Logar ve ark. McCormick iskelet koleksiyonundan 134 çağdaş beyaz bireye ait os hyoideum'u kullanarak cinsiyet tahmini çalışması yapmışlardır. Buna göre tek değişkenli diskriminant fonksiyonu ile doğruluk oranları %67,0-86,8; çok değişkenli diskriminant fonksiyonu doğruluk oranlarının ise %89-93 arasında olduğu belirtilmiştir [90]. Orta İtalya'daki 5 coğrafik bölgeden 64 yetişkin bireye ait os hyoideum'dan diskriminant fonksiyonu analizi ile %75-88 arasında cinsiyeti tahmin doğruluğuna ulaştığı belirtilmiştir [87]. Robert J. Terry Anatomik koleksiyonuna ait os hyoideum'dan cinsiyet tahmini için yapılan çalışmada, diskriminant fonksiyon analizi sonucunda %82-85 doğruluk oranı tespit edilmiştir [21]. Bu çalışmada ise

MobileNetV2 kullanılarak %91,7 cinsiyeti doğru sınıflandırdığı sonucuna ulaşıldı. Doğruluk oranında ulaşılan bu yüksek oranın çalışmamızda kullanılan os hyoideum sayısının diğer çalışmalara oranla fazla olması ve cinsiyet tahmininde derin öğrenme modellerinin diskriminant fonksiyon analizine göre daha yüksek doğruluk oranı verdiğini düşündürmektedir.

Fransa'da 88 sağlam kuru os hyoideum ve yaşayan yetişkin deneklerin BT tarama görüntülerinden 92 os hyoideum kullanarak araştırma yapmışlardır. Çalışma sonucunda geometrik morfometri yöntemiyle erkeklerin %89,5'inin ve kadınların %86,5'inin cinsiyet sınıflandırmasını doğru yaptığı saptanmıştır [98]. 293 Kuzeybatı Hint popülasyonundaki kadavralardan cinsiyeti tahmin etmek için alınmış os hyoideum dijital kumpasla ölçülmüştür. Makine öğrenme algoritmalarından XGBoost sınıflandırıcı kullanılarak elde edilen en yüksek doğruluk %83 olarak bildirilmiştir [25]. Doğu Türk popülasyonundaki 240 yetişkin bireye ait BT görüntüleri üzerinden yapılan ölçümlerle uygulanan diskriminant fonksiyon analizi ile %93,3, Destek Vektör Makinası (Support Vector Machines) kullanılarak %93,8, yapay sinir ağları kullanılarak %95,4 olduğu belirtilmiştir [91]. Torimitsu ve ark. 280 Japon kadavranın postmortem BT görüntüleri üzerinden os hyoideum'dan cinsiyet tahmininde stepwise diskriminant fonksiyon analizinde kaynaşmış olanlarda %94,1, kaynaşmamış olanlarda %93,3'lük oran olduğu açıklamışlardır [92]. Soltani ve ark. İran kökenli 349 yetişkin kadavrada logistik regresyon modelini kullanarak %97,4 oranında cinsiyeti doğru sınıflandırdığını saptamışlardır [15]. Okasi ve ark. 372 İranlı bireye ait BT görüntüsü üzerinden logistik regresyon kullanarak yapmış oldukları çalışmada %81,7 oranında cinsiyeti doğru sınıflandırdığını belirtmişlerdir [99]. Bu çalışmada bir CNN modeli olan EfficientNet V2B0 kullanılarak 1000 BT görüntüsü üzerinden elde edilen resimlerle cinsiyet tahminindeki en yüksek doğruluk oranının %95 olduğu görüldü. Doğu Türk popülasyonundaki doğruluk oranının bu çalışmaya göre yüksek olmasının sebebinin bizim çalışmamızdaki özellikle genç birey sayısının fazla olduğu kanaatindeyiz. İranlılarda Soltani ve ark.'na ait çalışmada doğruluk oranının bu kadar yüksek olmasının sebebi çalışmadaki en küçük kadavranın yaşının 25 olarak sınırlanmasıdır. Bu çalışmada ise en küçük yaş 15 olarak alındı. Ayrıca literatürdeki çalışmalara bakıldığında özellikle kaynaşmamış os hyoideum'lardan elde edilen doğruluk oranı kaynaşmışlara göre daha düşük olduğu saptanmıştır [21, 92].

Literatürde os hyoideum'u değerlendiren diğer çalışmalarda morfometrik olarak ölçümlerin yapılmış olduğu ancak cinsiyet tahmin oranının vermediği saptanmıştır [100-102]. Başka bir çalışmada 66 Suudi kadavradan elde edilen os hyoideum'un cinsiyet sınıflandırma oranı parametre bazında incelenmiştir. Buna göre maksimum corpus uzunluğu parametresi erkeklerde %93,79, kadınlarda %63,2; total os hyoideum uzunluğunun ise erkeklerde %100, kadınlarda %65,68 oranında cinsel dimorfizm gösterdiği belirtilmiştir [103]. Köse ve Göller Bulut'un 130 konik ışın BT görüntüsünde os hyoideum'un üzerinde yapmış oldukları ölçümde cinsiyet tahminine en önemli katkıyı corpus uzunluğunun %81,35 oranında ve os hyoideum'un boy ölçümlerinin %76,25 oranında sağladığı bildirilmiştir [104]. Söz konusu olan bu çalışmada ise cinsiyet tahmininde doğruluk oranları belirtilerek popülasyonlar, toplumlar arası karşılaştırma imkânı tanınmıştır.

Literatürde yapılmış bir çalışmaya göre bilateral os hyoideum füzyon düzeninde önemli bir farklılık olmadığını ve füzyonun kadınlarda erkeklere göre yaklaşık 5 yıl daha erken olduğu açıklanmıştır [105]. Başka bir çalışmaya göre 60 yaş üstü bireylerde füzyonun mutlaka artmış olduğu ancak cinsiyete göre fark göstermediği saptanmıştır [22]. İleri yaş kadavralarda yapılmış bir çalışmada os hyoideum'un bilateral tam füzyon oranı %51,5 ve bilateral kaynamama oranı %22,7 olarak görülmüştür [106]. Fisher ve ark. yapmış oldukları çalışmada nihayetinde os hyoideum'da olan füzyonun derecesi ve zamanlamasında geniş bir değişiklik gösterdiğini belirtmişler. Bilateral füzyonun olmamasının ise 20 yaşından sonra azalma eğilimi içinde olduğunu saptamışlardır [107]. Harjeet ve ark. yapmış oldukları araştırma her iki cinsiyetteki os hyoideum'da cornu majus'un corpus'la füzyonunun 25 yaşına kadar görülmediğini aktarmışlardır [108]. Dolayısıyla os hyoideum'un füzyon zamanı düzensiz olduğundan literatürdeki çalışmalar incelendiğinde en az 15 yaş, en yüksek de 102 yaş alındığı görüldü [25, 106]. Vohra ve Kulkarni yapmış oldukları cinsel dimorfizm çalışmasında 0-80 yaş arasındaki 300 os hyoideum'un kaliper kullanarak ölçümünü gerçekleştirmişlerdir. Çalışmanın sonucunda cinsiyet farklılıklarının 12 yaşına kadar önemsiz olduğunu lakin daha sonra erkeklerde ölçümler 25 yaşına kadar daha da arttığını, 12 yaş üstü kadınlarda ise 20 yaşına kadar hafif bir artış görüldüğünü daha sonra herhangi bir artış olmadığını açıklamışlardır [109]. Werner ve ark. doğumdan 19 yaşına kadar olan bireylere ait BT görüntüsü üzerinde yapmış olduğu çalışmada, 15

yaşından sonra özellikle erkeklerde açısız ölçümlerde cinsel dimorfizmin kademeli olarak arttığına yer vermişlerdir [110]. Dolayısıyla bu bilgiler ışığında çalışmamızdaki veri setinde de en küçük yaş 15 olarak alındı.

Listio, göze ait fotoğraflar üzerinden yapmış olduğu çalışmada 2681 görüntü üzerinden MobileNetV2 modeliyle cinsiyetin %89,3 oranında doğru sınıflandırıldığını bildirmiştir [74]. Kılıç ve Doğan 164 Asyalı bireye ait 28412 (Red-Green-Blue RGB) kulak görüntüsü MobileNetV2 modeli kullanarak cinsiyet tahmin oranını %85,55 vermiştir [111]. Bu çalışmada ise 7000 görüntü ile MobileNetV2 kullanılarak cinsiyeti %91,7 oranında doğru sınıflandırdığı sonucuna ulaşıldı. Doğruluk oranımızın diğer çalışmalara nazaran yüksek olmasının sebebinin uygun sayıda görüntü kullanıldığını düşündürmektedir.

Kumar ve Mishra insanların yüzlerinin maskelerle yapay olarak maskelenmesini kullanarak yapmış oldukları, yaş ve cinsiyet tahmin çalışmasında ResNet50 modeliyle %80 doğruluk oranına ulaşmışlardır [80]. Özdemir ve Bilgin Türkçe CommonVoiceTR-9.0 veri kümesindeki konuşma sinyalleri, ResNet50 modeli kullanarak cinsiyeti en yüksek %88,76 oranında sınıflandırdığını belirtmişlerdir [112]. Rajee ve Mythili farklı veri kümelerinden kopyalanan 1000 dış X-Ray görüntülerini kullanarak ResNet50 mimari modelindeki cinsiyeti doğru sınıflandırma oranı %98,27 olduğunu bildirmişler [113]. Venema ve ark. 417 yetişkin kuru kemik humerus'a ait 2D görüntülerini ResNet50 mimari modeli kullanarak cinsiyet tahmin çalışmasında %87,8 doğruluk oranına ulaşmışlardır [114]. Bu çalışmada ise ResNet50 derin öğrenme yöntemi kullanılarak cinsiyet tahminindeki doğruluk oranı %92,7 olarak elde edildi. Rajee ve Mythili'ye ait çalışmadaki oranın yüksek olmasının sebebi çalışmanın karma bir veri setinde uygulanmış olması ve %60 eğitim, %40 test seti olarak kullanmasına bağlı olarak gerçekleştiği kanaatindeyiz.

Video tabanlı yüz analizi yapılmış bir çalışmada EfficientNet B0 modeli kullanıldığında model başarısının %94,19 olduğu görülmüştür [115]. Hougaz ve ark. 16824 dışın X-Ray görüntüsünden cinsiyet sınıflandırmasındaki F1 skorunu EfficientNet B0 modeliyle %91,30, EfficientNetV2-Small modeliyle %89,10, EfficientNetV2-Large modeliyle %91,43 olarak açıklamışlardır [116]. Bu çalışmada

ise EfficientNet B0'da %94,3 ve EfficientNet V2B0 modelinde ise %95 olduğu görüldü.

Derin öğrenme mimari modelleri kullanıldığında aşırı uyum problemi ortaya çıkabilir. Böyle durumların üstesinden gelmek için veri sayısında artırma ve bırakma gibi düzenlemeler yapılır [52, 117-120]. Bu çalışmada da bu durumların üstesinden gelmek için veri sayısında artırma yapıldı.

Söz konusu olan bu çalışmada cinsiyeti tahmin etmek amacıyla kullanılan derin öğrenme yöntemlerindeki doğruluk oranları MobileNetV2'de %91,7, ResNet50'de %92,7, EfficientNet B0'da %94,3 ve en yüksek başarı EfficientNet V2B0 modelinde %95 olarak elde edildi. Literatürdeki bir çalışmada COVID-19 hastalık tespiti için 4350 yüksek kaliteli X-Ray görüntüleri kullanılmış olup hem ResNet50 hem de EfficientNet B0 modeliyle %99,11 oranları açıklanmıştır [121]. Başka bir çalışmada ise MRG beyin tümörlerinin doğru biçimde çoklu sınıflandırılması (glioma, meningioma ve hipofiz) için kullanılan test veri seti üzerinde elde edilen doğruluk derin öğrenme yöntemlerinden ResNet50 V2 de %95,4 ve EfficientNet B0 V2 de ise %96,04 olduğu bildirilmiştir [122]. EfficientNet derin öğrenme mimarisinin genellikle diğer modellere göre daha yüksek başarı gösterdiği görülmüştür.

Derin öğrenme yöntemlerinden 3170 eğitim ve 318 test verisi ile profil fotoğraflardan cinsiyet tahmininde denemeler sonucunda VGG16 modeliyle elde edilmiş en iyi başarı oranı %99,41 olarak aktarılmıştır [123]. Veri setinin 6147 maküler optik koherens tomografi görüntüsünden oluşturulmuş bir araştırmada derin öğrenme kullanılarak cinsiyet tahmini doğruluğu $85,6 \pm 2,1$ olarak saptanmıştır [124]. Oura ve ark. 100 iskelete ait diz radyografilerinden oluşmuş veri setinden MhNet tabanlı bir modelde %90,3'lük cinsiyet tahmin oranı belirtmişlerdir [125]. Kuzey Çin'deki Han popülasyonuna ait toplamda 10703 orthopantomogram görüntüsüyle çalışılmış olan CNN cinsiyet tahmininde yetişkinlerde %90,97'lik sınıflandırma oranı açıklanmıştır [126]. Literatürdeki cinsiyet tahmin çalışmaları incelendiğinde derin öğrenme yöntemleri aktif bir şekilde kullanıldığı saptandı.

BÖLÜM 6

SONUÇ VE ÖNERİLER

Söz konusu olan bu çalışmada boyun BT görüntülerinden sadece os hyoideum'un bulunduğu .jpeg görüntüleri elde edildi. Bu görüntüler ile derin öğrenme mimari modelleri kullanılarak cinsiyet tahmini yapıldı. Böylece os hyoideum üzerinden derin öğrenme modelleri kullanılarak cinsiyet tahmini yapılabileceği ortaya konuldu. CNN modellerinden EfficientNet V2B0 kullanıldığında en yüksek oran %95 olarak görüldü.

Çalışmadaki görüntüler os hyoideum'un yedi yönünden elde edildiği için uzmanların ellerinde herhangi bir açıdan resim bulunması, cinsiyet tahmini çalışmasında kullanılabileceğini gösterdi. Ayrıca çalışmada ölçüme bağlı olmadan sadece resimlerin değerlendirilmesiyle sonuç alınması cinsiyet tahminine daha kısa sürede ulaşma imkânı kazandıracak kanaatindeyiz.

Bu çalışmayla görüntüleme teknolojileri kullanımının güçlendirilmesi ve mükemmelleştirilmesine bir adım daha yaklaşılması amaçlandı. Gelecekte yalnızca yöntemlerin öznelliğini azaltmakla kalmayarak, cinsiyet tahminine karar verme sürecinde uzmanı destekleyecektir.

Bu noktada BT görüntülerinden elde edilen .jpeg resim görüntüleriyle MobileNetV2, ResNet50, EfficientNet B0 ve EfficientNet V2B0 derin öğrenme yöntemleri kullanılarak yapılmış bir çalışmaya rastlanmadı. Dolayısıyla çalışma literatürdeki bu eksiği kapatmak için yapıldı. EfficientNet'in hafif ve verimli bir mimari model olmasının avantajı kullanılarak, gelecekte mobil cihazlara yüklenebilir uygulama elde edildiğinde sadece fotoğraf çekimi yapılarak arkeolojik kazılarda ya da adli tıpta henüz olay yerindeyken bireyin cinsiyetinin saptanmış olacağı kanaatindeyiz.

KAYNAKLAR

1. Mello-Gentil, T. and V. Souza-Mello, "Contributions of anatomy to forensic sex estimation: focus on head and neck bones", *Forensic Sci Res*, 7(1): 11-23 (2022).
2. Cappariello, A., M. Ponzetti, and N. Rucci, "The “soft” side of the bone: unveiling its endocrine functions", *Hormone Molecular Biology and Clinical Investigation*, 28(1): 5-20 (2016).
3. Almeida, M. and C.A. O'Brien, "Basic biology of skeletal aging: role of stress response pathways", *Journals of Gerontology Series A: Biomedical Sciences and Medical Sciences*, 68(10): 1197-1208 (2013).
4. Dahal, A., D. McNevin, M. Chikhani, and J. Ward, "An interdisciplinary forensic approach for human remains identification and missing persons investigations", *Wiley Interdisciplinary Reviews: Forensic Science*, 5(4): e1484 (2023).
5. Üzün, I., Ö. Daregenli, G. Sirin, and Ö. Müslümanoğlu, "Identification procedures as a part of death investigation in Turkey", *The American Journal of Forensic Medicine and Pathology*, 33(1): 1-3 (2012).
6. Krishan, K., P.M. Chatterjee, T. Kanchan, S. Kaur, N. Baryah, and R. Singh, "A review of sex estimation techniques during examination of skeletal remains in forensic anthropology casework", *Forensic Science International*, 261: 165. e1-165. e8 (2016).
7. Hong, W.-H., "The progress and controlling situation of Daegu Subway fire disaster", *Fire Safety Science*, 6: s-5-1 (2004).
8. Akıncıoğlu, N.U., İ. Aslan, and Y. Doğan, "Afet Kurbanlarının Kimliklendirilmesinde Kullanılan Yöntemler ve Ülkemizdeki Durum", *Güvenlik Bilimleri Dergisi*, 10(1): 217-238 (2021).
9. Tsokos, M., R. Lessig, C. Grundmann, S. Benthous, and O. Peschel, "Experiences in tsunami victim identification", *International Journal of Legal Medicine*, 120(3): 185-187 (2006).
10. O'Donnell, C., M. Iino, K. Mansharan, J. Leditscke, and N. Woodford, "Contribution of postmortem multidetector CT scanning to identification of the deceased in a mass disaster: experience gained from the 2009 Victorian bushfires", *Forensic Science International*, 205(1-3): 15-28 (2011).

11. Leditschke, J., S. Collett, and R. Ellen, "Mortuary operations in the aftermath of the 2009 Victorian bushfires", *Forensic Science International*, 205(1-3): 8-14 (2011).
12. Wikipedi. 2023 Kahramanmaraş depremleri. [cited 2024 18.04.2024]; Available from:
https://tr.wikipedia.org/wiki/2023_Kahramanmara%C5%9F_depremleri#.
13. Caplova, Z., Z. Obertova, D.M. Gibelli, D. De Angelis, D. Mazzarelli, C. Sforza, and C. Cattaneo, "Personal identification of deceased persons: an overview of the current methods based on physical appearance", *Journal of Forensic Sciences*, 63(3): 662-671 (2018).
14. Sharma, G., S. Thakral, and P. Setia, "A novel approach towards identification: A case report and review of literature", *Journal of Forensic and Legal Medicine*, 100: 102616 (2023).
15. Soltani, S., K. Aghakhani, and F. Fallah, "Sex prediction potential of hyoid metric measurements in Iranian adults", *Legal Medicine*, 25: 6-10 (2017).
16. Sasani, H., Y. Etli, B. Tastekin, Y. Hekimoglu, S. Keskin, and M. Asirdizer, "Sex Estimation From Measurements of the Mastoid Triangle and Volume of the Mastoid Air Cell System Using Classical and Machine Learning Methods: A Comparative Analysis", *The American Journal of Forensic Medicine and Pathology*, 45(1)(2024).
17. Amin, W., M. Saleh, D. Othman, D. Salhab, and H. Thunaibat, "Osteometric assessment of the mastoids for gender determination in Jordanians by discriminant function analysis", *American Journal of Medical and Biological Research*, 3(4): 117-123 (2015).
18. Hekimoglu, Y., H. Sasani, Y. Etli, S. Keskin, B. Tastekin, and M. Asirdizer, "Sex Estimation From the Paranasal Sinus Volumes Using Semiautomatic Segmentation, Discriminant Analyses, and Machine Learning Algorithms", *The American Journal of Forensic Medicine and Pathology*, 44(4)(2023).
19. Jo, J.H., J.W. Park, J.H. Jang, and J.W. Chung, "Hyoid bone position as an indicator of severe obstructive sleep apnea", *BMC Pulmonary Medicine*, 22(1): 349 (2022).
20. Paik, N.-J., S.J. Kim, H.J. Lee, J.Y. Jeon, J.-Y. Lim, and T.R. Han, "Movement of the hyoid bone and the epiglottis during swallowing in patients with dysphagia from different etiologies", *Journal of Electromyography and Kinesiology*, 18(2): 329-335 (2008).
21. Kindschuh, S.C., T.L. Dupras, and L.W. Cowgill, "Determination of sex from the hyoid bone", *American Journal of Physical Anthropology*, 143(2): 279-284 (2010).

22. Balseven-Odabasi, A., E. Yalcinozan, A. Keten, R. Akçan, A.R. Tumer, A. Onan, N. Canturk, O. Odabasi, and A.H. Dinc, "Age and sex estimation by metric measurements and fusion of hyoid bone in a Turkish population", *Journal of Forensic and Legal Medicine*, 20(5): 496-501 (2013).
23. Demet Mutlu, G., M. Asirdizer, E. Kartal, S. Keskin, İ. Mutlu, and C. Goya, "Sex estimation from the hyoid bone measurements in an adult Eastern Turkish population using 3D CT images, discriminant function analysis, support vector machines, and artificial neural networks☆", *Legal Medicine*, 67: 102383 (2024).
24. Urbanová, P., P. Hejna, L. Zátoková, and M. Šafr, "What is the appropriate approach in sex determination of hyoid bones?", *Journal of Forensic and Legal Medicine*, 20(8): 996-1003 (2013).
25. Tyagi, A., P. Tiwari, P. Bhardwaj, and H. Chawla, "Prognosis of sexual dimorphism with unfused hyoid bone: Artificial intelligence informed decision making with discriminant analysis", *Science & Justice*, 61(6): 789-796 (2021).
26. Bewes, J., A. Low, A. Morphet, F.D. Pate, and M. Henneberg, "Artificial intelligence for sex determination of skeletal remains: Application of a deep learning artificial neural network to human skulls", *Journal of Forensic and Legal Medicine*, 62: 40-43 (2019).
27. Galante, N., R. Cotroneo, D. Furci, G. Lodetti, and M.B. Casali, "Applications of artificial intelligence in forensic sciences: Current potential benefits, limitations and perspectives", *International Journal of Legal Medicine*, 137(2): 445-458 (2023).
28. Elhan, A., "Anatomi Terimleri Sözlüğü. 1. Baskı ed. İstanbul: *Güneş Kitabevi*, 120 (2003).
29. Özbağ, D., Ş. Toy, D. Şenol, R.S. Bakıcı, and S. Akdoğan, ""İnsan" Anatomi Terimleri Sözlüğü, ed. D. Özbağ. İstanbul: *İstanbul Tıp Kitabevi*, 344 (2023).
30. Arıncı, K. and A. Elhan, "Anatomi. Vol, Cilt 1, Ankara: *Güneş Tıp Kitabevleri*, 50 (2020).
31. Arifoğlu, Y., "BRS Gross Anatomi. İstanbul: *İstanbul Tıp Kitabevleri*, 338 (2017).
32. Gülekon, İ.N. and T.V. Peker, "Lippincott Resimli Gözden Geçirme ANATOMİ. Ankara: *Ankara Nobel Tıp Kitabevleri* (2019).
33. Šavlovskis, J. and K. Raits. Anatomy Standard. 2021-2023 [cited 2024 30.03.2024]; Available from: <https://www.anatomystandard.com/ossa-et-juncturae/cranium/os-hyoideum.html>.
34. Arifoğlu, Y., "Her Yönüyle Anatomi. Gözden Geçirilmiş 1. Baskı ed. İstanbul: *İstanbul Tıp Kitabevi*, 73 (2017).

35. Moore, K. and M. Persaud, "İnsan Embriyolojisi (Klinik Yönleri ile). 1. Baskı ed. İstanbul: *Nobel Tıp Kitabevleri*, 560 (2002).
36. Moore, K., "The Developing Human. 4. ed, ed. K. Moore. Philadelphia: *W.B. Saunders Company* (1988).
37. Hart, D.A., "Sex Determination in Homo sapiens as a Multi-Step Process: Potential for Development of Variants and Sex Differences in Disease Risk", *Journal of Biomedical Science and Engineering*, 17(1): 13-34 (2024).
38. Curate, F., "The estimation of sex of human skeletal remains in the Portuguese identified collections: history and prospects", *Forensic Sciences*, 2(1): 272-286 (2022).
39. Chovalopoulou, M.-E., E. Valakos, and E. Nikita, "Skeletal sex estimation methods based on the Athens collection", *Forensic Sciences*, 2(4): 715-724 (2022).
40. Bakici, R.S., "Bilgisayarlı tomografi görüntüleri üzerinden hesaplanan os sacrum ve os coccygis uzunluklarının cinsiyete göre değerlendirilmesi", Yüksek Lisans, Karabük Lisansüstü Eğitim Enstitüsü, *Karabük Üniversitesi*. Anatomi. (2020).
41. Chansoria, H., R. Chandrakar, H. Chetana, N. Kamadal, S. Pamecha, H. Kaur, and R. Tiwari, "Age and Gender Estimation Using the Osseous Microanatomy", *Journal of Pharmacy and Bioallied Sciences*, 16(Suppl 1): S233-S235 (2024).
42. Buonasera, T., J. Eerkens, A. de Flamingh, L. Engbring, J. Yip, H. Li, R. Haas, D. DiGiuseppe, D. Grant, M. Salemi, C. Nijmeh, M. Arellano, A. Leventhal, B. Phinney, B.F. Byrd, R.S. Malhi, and G. Parker, "A comparison of proteomic, genomic, and osteological methods of archaeological sex estimation", *Scientific Reports*, 10(1): 11897 (2020).
43. Zhang, M., "Forensic imaging: a powerful tool in modern forensic investigation", *Forensic Sciences Research*, 7(3): 385-392 (2022).
44. Bolliger, S.A., L. Filograna, D. Spendlove, M.J. Thali, S. Dirnhofer, and S. Ross, "Postmortem imaging-guided biopsy as an adjuvant to minimally invasive autopsy with CT and postmortem angiography: a feasibility study", *American Journal of Roentgenology*, 195(5): 1051-1056 (2010).
45. Xue, Y., L. Lai, C. Liu, Y. Niu, and J. Zhao, "Perspectives on the death investigation during the COVID-19 pandemic". *Elsevier*. 126-128. (2020).
46. Dirnhofer, R., C. Jackowski, P. Vock, K. Potter, and M.J. Thali, "VIRTopsy: minimally invasive, imaging-guided virtual autopsy", *Radiographics*, 26(5): 1305-1333 (2006).

47. Şafak, E. and N. Barışçı, "Evrimsel Sinir Ağlarını Kullanarak Yaş ve Cinsiyet Tahmini-Age and Gender Prediction Using Convolutional Neural Networks", *Proc. ISMSIT, Ankara, Turkey*, (2018).
48. Jiang, F., Y. Jiang, H. Zhi, Y. Dong, H. Li, S. Ma, Y. Wang, Q. Dong, H. Shen, and Y. Wang, "Artificial intelligence in healthcare: past, present and future", *Stroke and Vascular Neurology*, 2(4)(2017).
49. Atila, Ü., M. Uçar, K. Akyol, and E. Uçar, "Plant leaf disease classification using EfficientNet deep learning model", *Ecological Informatics*, 61: 101182 (2021).
50. Shahinzadeh, H., A. Mahmoudi, A. Asilian, H.H. Sadrarhami, Mohammadreza, and Y. Saberi. "Deep Learning: A Overview of Theory and Architectures" in *2024 20th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP)* (2024).
51. Das, T.K., P.K. Roy, M. Uddin, K. Srinivasan, C.Y. Chang, and S. Syed-Abdul, "Early tumor diagnosis in brain MR images via deep convolutional neural network model", *Comput. Mater. Contin*, 68: 2413-2429 (2021).
52. Guo, Y., Y. Liu, A. Oerlemans, S. Lao, S. Wu, and M.S. Lew, "Deep learning for visual understanding: A review", *Neurocomputing*, 187: 27-48 (2016).
53. Schmidhuber, J., "Deep learning in neural networks: An overview", *Neural Networks*, 61: 85-117 (2015).
54. Metlek, S. and K. Kayaalp, "Derin öğrenme ve destek vektör makineleri ile görüntüden cinsiyet tahmini", *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(3): 2208-2228 (2020).
55. Shrestha, A. and A. Mahmood, "Review of deep learning algorithms and architectures", *IEEE access*, 7: 53040-53065 (2019).
56. Kumar, K. and G.S.M. Thakur, "Advanced applications of neural networks and artificial intelligence: A review", *International Journal of Information Technology and Computer Science*, 4(6): 57 (2012).
57. Nielsen, F., "Neural Networks algorithms and applications", *Niels Brock Business College*, 12(2001).
58. LeCun, Y., Y. Bengio, and G. Hinton, "Deep learning", *Nature*, 521(7553): 436-444 (2015).
59. Karaoğlan, B., "Görüntü İşleminin Convolution Neural Network (CNN) Modeli Kullanılarak Tarımsal Alanda Uygulanması: Hastalıklı Yaprak Tespiti", Yüksek Lisans, Yüksek Öğretim Kurumu, *Karabük Üniversitesi*. (2022).
60. Hwang, Y.-S. and S.-Y. Bang, "An efficient method to construct a radial basis function neural network classifier", *Neural Networks*, 10(8): 1495-1503 (1997).

61. Montazer, G.A., D. Giveki, M. Karami, and H. Rastegar, "Radial basis function neural networks: A review", *Comput. Rev. J*, 1(1): 52-74 (2018).
62. Kohonen, T., "The self-organizing map", *Neurocomputing*, 21(1-3): 1-6 (1998).
63. Zewen, L., L. Fan, Y. Wenjie, P. Shouheng, and Z. Jun, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects", *IEEE Transactions on Neural Networks and Learning Systems*, 33(12): 6999-7019 (2022).
64. Ramachandran, R., D. Rajeev, S. Krishnan, and P. Subathra, "Deep learning an overview", *International Journal of Applied Engineering Research*, 10(10): 25433-25448 (2015).
65. Aloysius, N. and M. Geetha. "A review on deep convolutional neural networks" in *2017 International Conference on Communication and Signal Processing (ICCSPP)*: IEEE (2017).
66. Lo, S.-C.B., H.-P. Chan, J.-S. Lin, H. Li, M.T. Freedman, and S.K. Mun, "Artificial convolution neural network for medical image pattern recognition", *Neural Networks*, 8(7-8): 1201-1214 (1995).
67. Fukushima, K., "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", *Biological Cybernetics*, 36(4): 193-202 (1980).
68. Gündüz, G., "Derin öğrenme ile fotoğraftan yaş ve cinsiyet tespiti", *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*. (2019).
69. Chougule, O., D. Katheria, K. Jain, and S. Shinde. "Tomato Blight Classification Using Transfer Learning and Fine Tuning" in *2022 2nd Asian Conference on Innovation in Technology (ASIANCON)*: IEEE (2022).
70. Mascarenhas, S. and M. Agarwal. "A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification" in *2021 International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications (CENTCON)* (2021).
71. Howard, A.G., M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, "Mobilenets: Efficient convolutional neural networks for mobile vision applications", *Cornell University arXiv preprint arXiv:1704.04861*(2017).
72. Dong, K., C. Zhou, Y. Ruan, and Y. Li. "MobileNetV2 Model for Image Classification" in *2020 2nd International Conference on Information Technology and Computer Application (ITCA)* (2020).

73. Sandler, M., A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen. "Mobilenetv2: Inverted residuals and linear bottlenecks" in *Proceedings of the IEEE Conference on Computer vision and Pattern Recognition* (2018).
74. Listio, S.W.P., "Performance of Deep Learning Inception Model and MobileNet Model on Gender Prediction Through Eye Image", *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 7(4): 2593-2601 (2022).
75. Ferjaoui, R., M.A. Cherni, F. Abidi, and A. Zidi. "Deep Residual Learning based on ResNet50 for COVID-19 Recognition in Lung CT Images" in *2022 8th International Conference on Control, Decision and Information Technologies (CoDIT)* (2022).
76. Sarwinda, D., R.H. Paradisa, A. Bustamam, and P. Anggia, "Deep learning in image classification using residual network (ResNet) variants for detection of colorectal cancer", *Procedia Computer Science*, 179: 423-431 (2021).
77. He, K., X. Zhang, S. Ren, and J. Sun. "Deep residual learning for image recognition" in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (2016).
78. Wu, Y., Y. He, and Y. Wang, "Multi-class weed recognition using hybrid CNN-SVM classifier", *Sensors*, 23(16): 7153 (2023).
79. Shivadekar, S., B. Kataria, S. Hundekari, K. Wanjale, V.P. Balpande, and R. Suryawanshi, "Deep Learning Based Image Classification of Lungs Radiography for Detecting COVID-19 using a Deep CNN and ResNet 50", *International Journal of Intelligent Systems and Applications in Engineering*, 11(1s): 241-250 (2023).
80. Kumar, B.A. and N.K. Misra, "Masked face age and gender identification using CAFFE-modified MobileNetV2 on photo and real-time video images by transfer learning and deep learning techniques", *Expert Systems with Applications*, 246: 123179 (2024).
81. Marques, G., D. Agarwal, and I. De la Torre Díez, "Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network", *Applied Soft Computing*, 96: 106691 (2020).
82. Tan, M. and Q. Le. "Efficientnet: Rethinking model scaling for convolutional neural networks" in *International Conference on Machine Learning*: PMLR (2019).
83. Dastour, H. and Q.K. Hassan, "A comparison of deep transfer learning methods for land use and land cover classification", *Sustainability*, 15(10): 7854 (2023).
84. Tan, M. and Q. Le. "Efficientnetv2: Smaller models and faster training" in *International Conference on Machine Learning*: PMLR (2021).

85. Bakici, R.S., Z. Oner, and S. Oner, "The analysis of sacrum and coccyx length measured with computerized tomography images depending on sex", *Egyptian Journal of Forensic Sciences*, 11(1): 1-13 (2021).
86. Zech, W.-D., G. Hatch, L. Siegenthaler, M.J. Thali, and S. Lössch, "Sex determination from os sacrum by postmortem CT", *Forensic Science International*, 221(1): 39-43 (2012).
87. D'Anastasio, R., J. Viciano, M. Di Nicola, D.T. Cesana, M. Sciubba, M. Del Cimmuto, A. Paolucci, A. Fazio, and L. Capasso, "Estimation of sex from the hyoid body in skeletal individuals from archeological sites", *HOMO*, 65(4): 311-321 (2014).
88. Kim, D.I., U.Y. Lee, D.K. Park, Y.S. Kim, K.H. Han, K.H. Kim, and S.H. Han, "Morphometrics of the hyoid bone for human sex determination from digital photographs", *Journal of Forensic Sciences*, 51(5): 979-984 (2006).
89. Ramchand, T., O.J. Choudhry, P.A. Shukla, S. Tomovic, A.B. Kuperan, and J.A. Eloy, "Management of Hyoid Bone Fractures:A Systematic Review", *Otolaryngology–Head and Neck Surgery*, 147(2): 204-208 (2012).
90. Logar, C.J., T.R. Peckmann, S. Meek, and S.G. Walls, "Determination of sex from the hyoid bone in a contemporary White population", *Journal of Forensic and Legal Medicine*, 39: 34-41 (2016).
91. Mutlu, G.D., M. Asirdizer, E. Kartal, S. Keskin, İ. Mutlu, and G. Cemil, "Sex estimation from the hyoid bone measurements in an adult Eastern Turkish population using 3D CT images, discriminant function analysis, support vector machines, and artificial neural networks☆", *Legal Medicine*, 67: 102383 (2024).
92. Torimitsu, S., Y. Makino, H. Saitoh, N. Ishii, D. Yajima, G. Inokuchi, A. Motomura, F. Chiba, R. Yamaguchi, and Y. Hoshioka, "Determination of sex on the basis of hyoid bone measurements in a Japanese population using multidetector computed tomography", *International Journal of Legal Medicine*, 132: 907-914 (2018).
93. Earnest, F., H. Baker Jr, D. Kispert, and E. Laws Jr, "Magnetic resonance imaging vs. computed tomography: advantages and disadvantages", *Clinical Neurosurgery*, 32: 540-573 (1985).
94. Florkow, M.C., K. Willemsen, V.V. Mascarenhas, E.H. Oei, M. van Stralen, and P.R. Seevinck, "Magnetic resonance imaging versus computed tomography for three-dimensional bone imaging of musculoskeletal pathologies: a review", *Journal of Magnetic Resonance Imaging*, 56(1): 11-34 (2022).
95. Mukhopadhyay, P.P., "Determination of sex from an autopsy sample of adult hyoid bones", *Medicine, Science and the Law*, 52(3): 152-155 (2012).

96. James, R. and S. Anitha, "Determination of Sex from Hyoid bone–Is it Feasible?", *Journal of Indian Academy of Forensic Medicine*, 44(3): 42-45 (2022).
97. Suganchander, A., "Determination of Sex from Hyoid Bone", *Madras Medical College, Chennai*. (2019).
98. Fakhry, N., L. Puymerail, J. Michel, L. Santini, C. Lebreton-Chakour, D. Robert, A. Giovanni, P. Adalian, and P. Dessi, "Analysis of hyoid bone using 3D geometric morphometrics: an anatomical study and discussion of potential clinical implications", *Dysphagia*, 28: 435-445 (2013).
99. Okasi, A., M. Sadeghian, and B. Behnoush, "Shakori Rad A. Sex identification by morphometric study of hyoid bone", *International Journal of Medical Toxicology and Forensic Medicine*, 8(4): 145-150 (2018).
100. Amgain, K., S. Adhikary, P. Thapa, K.R. Sharma, and S. Neupane, "Morphometric Study of Hyoid Bone and its Forensic Implication", *Europasian Journal of Medical Sciences*, 2(1): 69-75 (2020).
101. Sameera, S.S. and K. Rao, "Morphometric analysis and sexual dimorphism of hyoid bone in telangana population", *International Journal of Anatomy and Research*, (2019).
102. Kopuz, C. and G. Ortug, "Morfología Variable del Hueso Hioides en una Población de Anatolia: Consecuencias Clínicas-Un Estudio Cadavérico", *International Journal of Morphology*, 34(4): 1396-1403 (2016).
103. Moustafa, S., "Estimation of Sex from Hyoid Bone: A Preliminary Study with Medico-Legal Implications", *Ain Shams Journal of Forensic Medicine and Clinical Toxicology*, 29(2): 1-6 (2017).
104. Köse, E. and D. Göller Bulut, "The use of hyoid bone dimensions in age and sex estimation in a Turkish population: a cone-beam computed tomography study", *Folia Morphol (Warsz)*, 81(1): 183-189 (2022).
105. Gupta, A., A. Kohli, N.K. Aggarwal, and K. Banerjee, "Study of age of fusion of hyoid bone", *Legal Medicine*, 10(5): 253-256 (2008).
106. Ichijo, Y., Y. Takahashi, M. Tsuchiya, Y. Marushita, T. Sato, H. Sugawara, S. Hayashi, M. Itoh, and T. Takahashi, "Relationship between morphological characteristics of hyoid bone and mandible in Japanese cadavers using three-dimensional computed tomography", *Anatomical Science International*, 91(4): 371-381 (2016).
107. Fisher, E., D. Austin, H.M. Werner, Y.J. Chuang, E. Bersu, and H.K. Vorperian, "Hyoid bone fusion and bone density across the lifespan: prediction of age and sex", *Forensic Science, Medicine, and Pathology*, 12: 146-157 (2016).

108. Harjeet, K., S. Synghal, G. Kaur, A. Aggarwal, and P. Wahee, "Time of fusion of greater cornu with body of hyoid bone in Northwest Indians", *Legal Medicine*, 12(5): 223-227 (2010).
109. Vohra, P. and P. Kulkarni, "Sexual dimorphism of human hyoid bone", *International Journal of Anatomy and Research*, 5(1): 3607-3610 (2017).
110. Werner, H.M., C.A. Miller, K.K. Tillman, Y. Wang, and H.K. Vorperian, "Growth and sexual dimorphism of the hyoid bone and its relationship to the mandible from birth to 19 years: A three-dimensional computed tomography study", *The Anatomical Record*, 304(9): 1901-1917 (2021).
111. Kılıç, Ş. and Y. Doğan, "Deep learning based gender identification using ear images", *Traitement du Signal*, 40(4)(2023).
112. Özdemir, Ö. and G. Bilgin. "Comprehensive Analysis of Deep Learning Methods on Gender Identification Using Speech Signals" in *2022 Innovations in Intelligent Systems and Applications Conference (ASYU)*: IEEE (2022).
113. Rajee, M. and C. Mythili, "Gender classification on digital dental x-ray images using deep convolutional neural network", *Biomedical Signal Processing and Control*, 69: 102939 (2021).
114. Venema, J., D. Peula, J. Irurita, and P. Mesejo, "Employing deep learning for sex estimation of adult individuals using 2D images of the humerus", *Neural Computing and Applications*, 35(8): 5987-5998 (2023).
115. Savchenko, A.V. "Video-based frame-level facial analysis of affective behavior on mobile devices using EfficientNets" in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2022).
116. Hougaz, A.B., D. Lima, B. Peters, P. Cury, and L. Oliveira. "Sex estimation on panoramic dental radiographs: A methodological approach" in *Anais do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde*: SBC (2023).
117. Ikechukwu, A.V., S. Murali, R. Deepu, and R. Shivamurthy, "ResNet-50 vs VGG-19 vs training from scratch: A comparative analysis of the segmentation and classification of Pneumonia from chest X-ray images", *Global Transitions Proceedings*, 2(2): 375-381 (2021).
118. Barrion, M.H.C., L.A.C. Fernando, M.K. Cabatuan, and A.A. Bandala. "Mobile Phone Decoder of Two-Cell Contracted Braille for Filipino Words Using Convolutional Neural Networks" in *2023 IEEE Region 10 Symposium (TENSymp)*: IEEE (2023).
119. Mikołajczyk, A. and M. Grochowski. "Data augmentation for improving deep learning in image classification problem" in *2018 International Interdisciplinary PhD Workshop (IIPhDW)*: IEEE (2018).

120. Ying, X. "An overview of overfitting and its solutions" in *Journal of Physics: Conference Series*: IOP Publishing (2019).
121. Talukder, M.A., M.A. Layek, M. Kazi, M.A. Uddin, and S. Aryal, "Empowering covid-19 detection: Optimizing performance through fine-tuned efficientnet deep learning architecture", *Computers in Biology and Medicine*, 168: 107789 (2024).
122. Mzoughi, H., I. Njeh, M.B. Slima, N. Farhat, and C. Mhiri. "Deep Transfer Learning (DTL) Based-Framework for an Accurate Multi-classification of MRI Brain Tumors" in *2023 International Conference on Cyberworlds (CW)*: IEEE (2023).
123. Gündüz, G. and İ.H. Cedimoğlu, "Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini", *Sakarya University Journal of Computer and Information Sciences*, 2(1): 9-17 (2019).
124. Chueh, K.-M., Y.-T. Hsieh, H.H. Chen, I.-H. Ma, and S.-L. Huang, "Identification of sex and age from macular optical coherence tomography and feature analysis using deep learning", *American Journal of Ophthalmology*, 235: 221-228 (2022).
125. Oura, P., J.-A. Junno, D. Hunt, P. Lehenkari, J. Tuukkanen, and H. Maijanen, "Deep learning in sex estimation from knee radiographs—A proof-of-concept study utilizing the Terry Anatomical Collection", *Legal Medicine*, 61: 102211 (2023).
126. Bu, W.-q., Y.-x. Guo, D. Zhang, S.-y. Du, M.-q. Han, Z.-x. Wu, Y. Tang, T. Chen, Y.-c. Guo, and H.-t. Meng, "Automatic sex estimation using deep convolutional neural network based on orthopantomogram images", *Forensic Science International*, 348: 111704 (2023).

EK AÇIKLAMALAR A.

ONAY YAZISI

Ek 1. Etik Kurul Onay Yazısı



T.C
İZMİR BAKIRÇAY ÜNİVERSİTESİ
GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALARI ETİK KURULU
KARAR

	AÇIK ADRESİ	Gazi Mustafa Kemal Mah. Kaynaklar Cad. Seyrek MENEMEN /İZMİR			
	TELEFON	0232 493 00 00-11126			
	FAKS	0232 844 71 22			
SORUMLU ARAŞTIRMACI	Doç.Dr. Zülal ÖNER				
YARDIMCI ARAŞTIRMACILAR	Araş.Gör. Rukiye Sümeyye BAKICI, Doç.Dr. Serkan ÖNER, Dr.Öğr.Üyesi Muhammet ÇAKMAK				
ARAŞTIRMANIN AÇIK ADI	Bilgisayarlı Tomografi Görüntülerinden Os Hyoideum'un EfficientNet Derin Öğrenme Modeli Kullanılarak Cinsiyet Tahmini				
KARAR	Karar No: 970	Araştırma No: 950	Tarih: 05.04.2023		
	Sorumlu araştırmacısı Doç.Dr. Zülal ÖNER olan "Bilgisayarlı Tomografi Görüntülerinden Os Hyoideum'un EfficientNet Derin Öğrenme Modeli Kullanılarak Cinsiyet Tahmini" başlıklı araştırmann etik açıdan UYGUN OLDUĞUNA oy birliği ile karar verildi.				
ETİK KURUL DAYANAKLARI	İyi Klinik Uygulamaları (IKU) Kılavuzu ve bununla ilgili Avrupa Birliği Direktifleri, Dünya Tıp Birliği Helsinki Bildirgesi, Biyoloji ve Tıbbın Uygulanması Bakımından İnsan Hakları ve İnsan Haysiyetinin Korunması Sözleşmesi, İnsan Hakları ve Biyotıp Sözleşmesinin Onaylanmasının Uygun Bulduğuna Dair Kanun, Hasta Hakları Yönetmeliği, Türk Ceza Kanunu, Sağlık Hizmetleri Temel Kanunu, Yükseköğretim Kanunu, Klinik Araştırmalar Hakkında Yönetmelik, Tıbbi Deontoloji Tüzüğü, Türk Tabipler Birliği Hekimlik Meslek Etiği Kuralları, Yükseköğretim Kurulu'nun Bilimsel Araştırma ve Yayın Etiği Yönergesi				
Etik Kurul Üyeleri Unvanı Adı Soyadı	Uzmanlık Alanı	Araştırma ile ilişki		Katılım	İmza
Prof. Dr. Hanefi ÖZBEK Etik Kurul Başkanı	Farmakoloji	<input type="checkbox"/> E	<input checked="" type="checkbox"/> H	<input checked="" type="checkbox"/> E	<input type="checkbox"/> H
Prof. Dr. Nazan KILIÇ AKÇA Üye	İç Hastalıkları Hemşireliği	<input type="checkbox"/> E	<input checked="" type="checkbox"/> H	<input checked="" type="checkbox"/> E	<input type="checkbox"/> H
Dr. Öğr. Üyesi Kadirhan ÖZDEMİR Üye	Fizyoterapi ve Rehabilitasyon	<input type="checkbox"/> E	<input checked="" type="checkbox"/> H	<input checked="" type="checkbox"/> E	<input type="checkbox"/> H
Dr. Öğr. Üyesi Pelin KOCA Üye	Farmakoloji	<input type="checkbox"/> E	<input checked="" type="checkbox"/> H	<input checked="" type="checkbox"/> E	<input type="checkbox"/> H
Dr. Öğr. Üyesi Seda ÇETİNKAYA KARABEKİR Üye	Histoloji ve Embriyoloji	<input type="checkbox"/> E	<input checked="" type="checkbox"/> H	<input checked="" type="checkbox"/> E	<input type="checkbox"/> H

ÖZGEÇMİŞ

Rukiye Sümeyye BAKICI ilk, orta ve lise öğrenimini Osmaniye’de, Lisans eğitimini 2017’de Hatay Mustafa Kemal Üniversitesi Fizik Tedavi ve Rehabilitasyon Yüksekokulu’nda tamamladı. 2018 yılında Karabük Üniversitesi Anatomi Anabilim Dalı’nda yüksek lisansa başlayıp 2020 yılında mezun oldu. Akabinde doktora eğitimine devam etmiştir. 2019 yılında Karabük Üniversitesi Tıp Fakültesi Anatomi Anabilim Dalı’nda araştırma görevlisi olarak çalışmaya başlamıştır. Halen görevine devam etmektedir.