

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ANATOMİ ANABİLİM DALI



FASİYAL MORFOMETRİK ÖLÇÜMLERİN VE MAKİNE
ÖĞRENMESİ ALGORİTMALARININ ERİŞKİN BİREYLERİN
CİNSİYET TAYİNİNDE KULLANILABİLİRLİĞİNİN
DEĞERLENDİRİLMESİ
YÜKSEK LİSANS TEZİ

HİLAL IŞIK ROZAN

TEZ DANIŞMANI

Dr. Öğretim Üyesi Murat DIRAMALI

İKİNCİ TEZ DANIŞMANI

Doç. Dr. Seval BAYRAK

BOLU, TEMMUZ - 2024

KABUL VE ONAY SAYFASI

Hilal IŞIK ROZAN tarafından hazırlanan “**Fasiyal Morfometrik Ölçümlerin ve Makine Öğrenmesi Algoritmalarının Erişkin Bireylerin Cinsiyet Tayininde Kullanılabilirliğinin Değerlendirilmesi**” adlı tez çalışması jürimiz tarafından Anatomi Anabilim Dalı’nda Yüksek Lisans Tezi olarak oy birliği ile kabul edilmiştir. 23/07/2024

Jüri Üyeleri

İmza

Danışman
Dr. Öğretim Üyesi Murat Dıramalı
Bolu Abant İzzet Baysal Üniversitesi

.....

Üye
Prof. Dr. İbrahim Kürtül
Bolu Abant İzzet Baysal Üniversitesi

.....

Üye
Doç. Dr. Deniz Şenol
Düzce Üniversitesi

.....

Lisansüstü Eğitim Enstitüsü Onayı

Prof. Dr. İbrahim KÜRTÜL
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

Bolu Abant İzzet Baysal Üniversitesi, Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu bildirir,

aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Teze ilişkin Turnitin adlı programında enstitü müdürlüğünce belirlenen filtrelemeler uygulanarak alınmış olan benzerlik raporuna göre, tezin benzerlik oranı %30'u geçmemektedir.

Bu çalışma için Bolu Abant İzzet Baysal Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulundan 87 sayılı, 2024/81 Karar numarası ile etik izin alınmıştır.

.....
HİLAL IŞIK ROZAN

ÖZET

FASİYAL MORFOMETRİK ÖLÇÜMLERİN VE MAKİNE ÖĞRENMESİ ALGORİTMALARININ ERİŞKİN BİREYLERİN CİNSİYET TAYİNİNDE KULLANILABİLİRLİĞİNİN DEĞERLENDİRİLMESİ

YÜKSEK LİSANS TEZİ

Hilal IŞIK ROZAN

BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ANATOMİ ANABİLİM DALI

(TEZ DANIŞMANI: DR. ÖĞRETİM ÜYESİ MURAT DIRAMALI)

(İKİNCİ DANIŞMAN: DOÇ. DR. SEVAL BAYRAK

BOLU, TEMMUZ - 2024

XII + 54

Maksiller sinüs, nazal kavite ve zigomatik arkta bulunan anatomik yapılardan kadın ve erkek bireylerde yapılan morfometrik ölçümler ile makine öğrenme algoritmalarını kullanarak cinsiyetler arasında anlamlı farklılık olup olmadığını ortaya koymak amaçlandı.

Mann-Whitney U Testi ile analizi sonucunda; sağ maksiller sinüs yüksekliği, sol maksiller sinüs genişliği ve yüksekliğinin, sol nazal kavite genişliğinin, sol zigomatik ark genişliğinin, sağ nazal kavite yüksekliği ve genişliğinin, sağ zigomatik ark yüksekliği ve genişliği değişkenlerinin erkeklerde kadınlardan istatistiksel olarak anlamlı fazla olduğu bulundu.

Rastgele Orman Sınıflandırma, Karar Ağacı, K-En Yakın Komşu, Gaussian Naive Bayes, Doğrusal Diskriminant Analizi, Destek Vektör Makinesi algoritmaları kullanıldı. Doğruluk skoruna bakıldığında bilateralde eğitim seti için %84, test seti için %83 ile Lojistik Regresyon modeli en efektif algoritmaydı. İlgili bölgelerdeki anatomik yapıların morfometrik ölçümleri kullanılarak cinsiyet belirlemede, makine öğrenmesi algoritmalarının kullanılabileceği sonucuna varıldı.

ANAHTAR KELİMELE: Maksiller sinüs, Zigomatik Ark, Nazal Kavite, Makine Öğrenmesi, Cinsiyet Tahmini.

ABSTRACT

EVALUATION OF THE USABILITY OF FACIAL MORPHOMETRIC MEASUREMENTS AND MACHINE LEARNING ALGORITHMS IN GENDER DETERMINATION OF ADULT INDIVIDUALS

MSC THESIS

HİLAL IŞIK ROZAN

BOLU ABANT İZZET BAYSAL UNIVERSITY

INSTITUTE OF GRADUATE STUDIES

DEPARTMENT OF ANATOMY

(SUPERVISOR: ASSIST. PROF. DR. MURAT DIRAMALI)

(CO-SUPERVISOR: ASSOCIATE PROFESSOR DOCTOR SEVAL BAYRAK)

BOLU, JUNE 2024

XII + 54

The aim was to determine whether there is a significant difference between genders using morphometric measurements taken from anatomical structures in the Maxillary Sinus, Nasal Cavity, and Zygomatic Arch, along with machine learning algorithms.

A total of 752 individuals, including 344 males and 408 females who met the inclusion and exclusion criteria, applied to the Abant İzzet Baysal University Faculty of Dentistry between 2015 and 2023, were included in the study. Morphometric measurements were performed on 12 parameters located in the maxillary sinus, nasal cavity, and zygomatic arch using the I-Cat Vision program in the Department of Oral, Dental, and Maxillofacial Radiology, Tomography Imaging, and Reporting Room.

As a result of analysis with Mann-Whitney U Test; It was found that the variables of right maxillary sinus height, left maxillary sinus width and height, left nasal cavity width, left zygomatic arch width, right nasal cavity height and width, and right zygomatic arch height and width variables were statistically significantly higher in men than in women.

Random Forest, Decision Tree, K-Nearest Neighbor, Gaussian Naive Bayes, Linear Discriminant Analysis, and Support Vector Machine algorithms were used. Considering the accuracy score, the Logistic Regression model was the most effective algorithm with 84% for the training set and 83% for the test set in bilateral.

It was concluded that machine learning algorithms could be used for gender determination using morphometric measurements of relevant anatomical structures.

KEYWORDS: Maxillary Sinus, Zygomatic Arch, Nasal Cavity, Machine Learning, Gender Prediction.

İÇİNDEKİLER

Sayfa

KABUL VE ONAY SAYFASI	iii
ETİK BEYAN.....	iv
ÖZET.....	v
ABSTRACT	vi
İÇİNDEKİLER	vii
ŞEKİL LİSTESİ.....	viii
TABLO LİSTESİ	ix
KISALTMA VE SEMBOLLER LİSTESİ	x
TEŞEKKÜR	xii
1. GİRİŞ.....	1
2. GENEL BİLGİLER	3
2.1 Embriyoloji.....	3
2.2 Anatomi	4
2.2.1 Kranium	4
2.3 Paranasal Sinüsler.....	9
2.3.1 Frontal Sinüs.....	9
2.3.2 Maksiller Sinüs	10
2.3.3 Etmoidal Sinüs.....	10
2.3.4 Sfenoidal Sinüs	10
2.4 Nazal Kavite	11
2.5 Cinsiyet Tahmini ve Yöntemleri	11
2.6 Yapay Zekâ ve Makine Öğrenmesi	13
3. GEREÇ VE YÖNTEM	17
4. BULGULAR	20
5. TARTIŞMA	39
6. SONUÇ VE ÖNERİLER	47
7. KAYNAKLAR.....	48
8. EKLER.....	54

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Kraniyumun Önden Görünümü (33).	8
Şekil 2.2. Kraniyumun Yandan Görünümü (33).	8
Şekil 2.3. Kraniyumun Sagital Kesiti (33).	9
Şekil 2.4. Paranasal Sinüsler (37).	11
Şekil 3.1. Maksiller Sinüslerin En Geniş Yerinden Mediolateral Ölçümü.	18
Şekil 3.2. Maksiller Sinüslerin En Uzun Mesafeden Superoinferior Ölçümü.	18
Şekil 3.3. Nazal Kavitenin En Geniş Mesafeden Mediolateral Ölçümü.	18
Şekil 3.4. Nazal Kavitenin En Uzun Mesafeden Superoinferior Ölçümü.	18
Şekil 3.5. Zigomatik Arkın En Geniş Yerinden Mediolateral Ölçümü.	18
Şekil 3.6. Zigomatik Arkın En Uzun Mesafeden Superoinferior Ölçümü.	19
Şekil 4.1. Cinsiyete Göre Sayım Grafiği.	20
Şekil 4.2. Sağ Tarafa Yapılan Ölçümlere Ait Histogram Grafiği.	20
Şekil 4.3. Sol Tarafa Yapılan Ölçümlere Ait Histogram Grafiği.	21
Şekil 4.4. Değişkenlere Ait Kutu Grafiği.	22
Şekil 4.5. Değişkenlerin Korelasyonlarını Gösteren Isı Haritası.	23
Şekil 4.6. Bilateral Ölçümlerin LDA Modeline Ait Konfüzyon Matrisi.	26
Şekil 4.7. Bilateral Ölçümlerin LR Modeline Ait Konfüzyon Matrisi.	26
Şekil 4.8. Bilateral Ölçümlerin DTC Modeli Konfüzyon Matrisi.	27
Şekil 4.9. Bilateral Ölçümlerin RFC Modeline Ait Konfüzyon Matrisi.	27
Şekil 4.10. Bilateral Ölçümlerin SVC Modeline Ait Konfüzyon Matrisi.	28
Şekil 4.11. Bilateral Ölçümlerin KNN Modeline Ait Konfüzyon Matrisi.	28
Şekil 4.12. Bilateral Ölçümlerin GNB Modeline Ait Konfüzyon Matrisi.	29
Şekil 4.13. Sağ Tarafa Ait LDA Konfüzyon Matrisi.	30
Şekil 4.14. Sağ Tarafa Ait LR Konfüzyon Matrisi.	30
Şekil 4.15. Sağ Tarafa Ait DTC Modeli Konfüzyon Matrisi.	31
Şekil 4.16. Sağ Tarafa Ait RFC Modeli Konfüzyon Matrisi.	31
Şekil 4.17. Sağ Tarafa Ait SVC Modeli Konfüzyon Matrisi.	32
Şekil 4.18. Sağ Tarafa Ait KNN Modeli Konfüzyon Matrisi.	32
Şekil 4.19. Sağ Tarafa Ait GNB Modeli Konfüzyon Matrisi.	33
Şekil 4.20. Sol Tarafa Ait LDA Konfüzyon Matrisi.	34
Şekil 4.21. Sol Tarafa Ait LR Modeli Konfüzyon Matrisi.	35
Şekil 4.22. Sol Tarafa Ait DTC Modeli Konfüzyon Matrisi.	35
Şekil 4.23. Sol Tarafa Ait RFC Modeli Konfüzyon Matrisi.	36
Şekil 4.24. Sol Tarafa Ait SVC Modeli Konfüzyon Matrisi.	36
Şekil 4.25. Sol Tarafa Ait KNN Modeli Konfüzyon Matrisi.	37
Şekil 4.26. Sol Tarafa Ait GNB Modeli Konfüzyon Matrisi.	37

TABLO LİSTESİ

Sayfa

Tablo 4.1. Shapiro-Wilk Analizi Sonuçları.....	21
Tablo 4.2. Parametrik Olmayan Değişkenlerin Tanımlayıcı İstatistikleri.....	22
Tablo 4.3. Mann-Whitney U Testi	23
Tablo 4.4. Box-Tidwell Transformasyonu Sonrası Klasifikasyon Tablosu.....	24
Tablo 4.5. Bilateral Ölçümlerin Regresyon Katsayıları.....	24
Tablo 4.6. Sağ Taraftan Yapılan Ölçümlerin Regresyon Katsayıları.....	25
Tablo 4.7. Sol Taraftan Alınan Ölçümlerin Regresyon Katsayıları.....	25
Tablo 4.8. Bilateral Modelin Klasifikasyon Metrikleri.....	29
Tablo 4.9. Sağ Tarafa Ait Modelin Klasifikasyon Metrikleri.....	34
Tablo 4.10. Sol Tarafa Ait Modelin Klasifikasyon Metrikleri.....	38

KISALTMA VE SEMBOLLER LİSTESİ

3B	: Üç Boyutlu
AP	: Anteroposterior
BT	: Bilgisayarlı Tomografi
CAA	: Çeyrekler Arası Aralık
DT	: Karar Ağacı
GNB	: Gaussian Naive Bayes
KIBT	: Konik Işınlı Bilgisayarlı Tomografi
KNN	: K-En Yakın Komşu
LDA	: Doğrusal Diskriminant Analizi
LMSD	: Sol Maksiller Sinüs Genişliği
LMSH	: Sol Maksiller Sinüs Yüksekliği
LNCD	: Sol Nazal Kavite Genişliği
LNCH	: Sol Nazal Kavite Yüksekliği
LR	: Lojistik Regresyon
LZAD	: Sol Zigomatik Ark Genişliği
LZAH	: Sol Zigomatik Ark Yüksekliği
MAX	: Maksimum
MİN	: Minimum
ML	: Mediolateral
MRG	: Manyetik Rezonans Görüntüleme
ORT	: Ortalama
PROC	: Proccecus
RFC	: Rastgele Orman Sınıflandırma
RMSD	: Sağ Maksiller Sinüs Genişliği
RMSH	: Sağ Maksiller Sinüs Yüksekliği

RNCD	: Sağ Nazal Kavite Geniřlięi
RNCH	: Sağ Nazal Kavite Yükseklięi
RZAD	: Sağ Zigomatik Ark Geniřlięi
RZAH	: Sağ Zigomatik Ark Yükseklięi
SI	: Superoinferior
SD	: Standar Sapma
SVC	: Destek Vektör Makinesi



TEŞEKKÜR

Yüksek lisans eğitimim boyunca emeklerini ve desteğini sakınmayan, deneyim ve ilminden faydalanmamı sağlayan, öğrencisi olmaktan onur duyduğum tez danışmanım Dr. Öğretim Üyesi Murat DIRAMALI'ya,

Tezimin radyolojik ölçümleri aşamasında, sağladığı destek ve yardım için Ağız ve Çene Radyolojisi Ana Bilim Dalından değerli hocam Doç. Dr. Seval BAYRAK'a,

Ana Bilim Dalı Başkanımız ve Enstitü Müdürümüz Prof. Dr. İbrahim KÜRTÜL'e, yüksek lisans eğitimim süresince her daim bana kapısı açık olan Öğretim Üyelerimiz; Doç. Dr. Seda SERTEL MEYVACI, Doç. Dr. Gamze TAŞKIN ŞENOL ve Dr. Öğretim Üyesi Saadet ERDEM'e, üç dönem boyunca donanım kazanmam için çaba veren Tıbbi Biyoistatistik Ana Bilim Dalından çok değerli hocam Prof. Dr. Seyit Ali Kayış'a, Ana Bilim Dalımızın güler yüzlü Araştırma görevlileri Gülçin RAY ve Ece Zeliha KAPICI'ya,

Yüksek lisans eğitimim boyunca beni tolere edip, motivasyonumu arttırmaktan asla geri durmayan çok değerli iş arkadaşlarım; Uzm. Dr. Ferda AKSEL, Uzm. Dr. Selma ÇUKUR, Uzm. Dr. Nur TUNÇ KARABEKİROĞLU, Meral BAYDAR, Zeliha AVCI, Gonca ÇOBANOĞLU, Sevgi ÇELİKTAŞ, Esma ŞEN YILMAZ ve Yasemin ERYILMAZ'a,

Lisansüstü eğitime başlamamda büyük etken olan, yoğunluğum sebebiyle var olamadığım bütün rutinlerde ve her etkinlikte çocuklarımıza eksikliğimi hissettirmeyen Sinan ROZAN'a,

Beni sabırla ve sevgiyle yetiştiren, her koşulda yanımda kalabilen, elleri Cennet kapısı açası, çok kıymetli annem, babam ve kilometrelerce uzakta olsa da daima anaç varlığını hissettiren biricik ablam Hatice IŞIK SEZGİN'e,

Bu süreçte zaman zaman ihmal ettiğim, okul, sınav, mesai ve nöbetlerim dâhil evde olamadığım bütün günlerde özlemle beni bekleyen, yaşam sevincim iki gözüm canım oğullarım Mehmetan ve Ömer Alp'e teşekkürlerimle...

Hilal IŞIK ROZAN

1. GİRİŞ

İnsana ait kalıntıların kimliklendirilmesi sürecinde ilk aşama cinsiyet, yaş, boy ve etnik kökenden oluşan bir biyolojik profil oluşturmaktır (1). Bu aşamada cinsiyet tayini sayesinde incelenecek popülasyonu yarı yarıya azaltmak mümkündür. Sekonder seks karakterlerinin gelişim süreci puberte sonrasında tamamladığı için yetişkin olmayan kalıntılardan cinsiyet tayini her zaman güvenilir olmayabilir. Bütün bir erişkin iskeletinden cinsiyet tayini kesine yakın bir doğrulukta yapılabilse dahi adli bağlamda incelenen iskeletler kimi zaman bütünlüğünü kaybetmiş halde olabilmektedir. Parçalanmış, yanmış ya da herhangi bir şekilde tahribata uğramış vakalarda kompakt ve dayanıklı yapıdaki kemikler antropolojik incelemeler için önem teşkil etmektedir (2, 3, 4).

Bütünlüğünü koruyan iskelet ile ender olarak karşılaşıldığı yapılan çalışmalarda belirtilmiştir (5). Bu nedenle başta kraniyum olmak üzere kemik yapı vasıtasıyla cinsiyet tayin edilmektedir. Bütünlüğünü korumakta olan iskeletlerde cinsiyet tahmini yüksek doğrulukta yapılabilen iken parçalanmış yahut küçük kemik parçacıklarının kaldığı kafatası kemiklerinde tahminler için bilgi ve teknikler oldukça sınırlıdır (5). En dimorfik olan bölgeler pelvis ve kraniyumdur (6). Maksiller sinüs; vücudun yakıldığı, kafatası ve diğer kemiklerin ağır hasar gördüğü durumlarda dahi sağlam kalabildiğinden mütevellit cinsiyet tespiti için kullanılabilir (7).

Radyolojik incelemelerin; kolay erişilebilir oluşu, diğer yöntemlere nazaran ucuz olması, tekrarlanabilen ölçümler sağlaması gibi avantajları adli antropoloji araştırmalarında sıklıkla tercih edilmesine sebep olmaktadır (8).

Konik Işınli Bilgisayarlı tomografi (KIBT) bireyin kimliklendirilmesinde, geleneksel yöntemlere nispetle güvenilirliği ve tekrarlanabilirliği artırmaktadır. Geniş ve gelişmiş bir veri kaynağı sunması hasebiyle cinsiyet tahmini çalışmalarında ön plana çıkmaktadır. Geleneksel antropolojik yöntemlerin sistematikleşmesini sağlayarak daha hassas ölçüm imkânı sağlamaktadır (9,10).

Günümüzde, yapay zekâ yöntemlerinden biri olan makine algoritmalarının sağlık sektöründe kullanımı yaygınlaşmıştır (11). Yapay zekâ yöntemlerinin sağlık alanına başlıca katkılarına; tanı koymayı kolaylaştırması, hasta ve hastalık takibinin planlanması, tedavi maliyetlerinin muhasebe edilmesi örnek verilebilir. Makine algoritmaları hastalara ait verileri kullanarak uygun algoritmalar ile

sınıflandırır, yeni verilerden bu sınıflandırmadan referans olarak tahminlerde bulunur (12).

Adli antropoloji çalışmalarında biyolojik profil meydana getirilirken istatistik yöntemlerinden; Lojistik Regresyon analizi, Diskriminant Analizi gibi metotlar kullanılmakta iken günümüzde makine öğrenmesi algoritmaları da tercih edilmeye başlanmıştır (13, 14).

Makine öğrenmesi yönteminde belirli algoritmaları işlemeyi öğrenen makinelerle, verilerden istenen çeşitli bilgilere erişmeye çalışılır. Makine öğrenimi, otomatik bir model oluşturarak veriler üzerinde analiz yapmayı hedefler. Tarafsızdır, yorulmaz, duyguları yoktur ve bu şekilde daha verimli ve yansız çalışabilir. Makine öğrenme algoritmalarının Gaussian Naive Bayes, Karar Ağacı, Rastgele Orman, Destek Vektör Makinesi, K-En Yakın Komşu gibi pek çok öğrenme çeşidi mevcuttur (15, 16).

Yapılan literatür taramasında zigomatik ark ve nazal kavitenin radyografik ölçümlerinden cinsiyet tahminine yönelik çalışmaların yeterli olmadığı görülmüştür. Buna binaen çalışmamızda maksiller sinüsün radyografik ölçümlerinin yanı sıra zigomatik ark ve nazal kavitenin ölçümlerinden elde edilen verilere de yer verdik.

Çalışmamızda Bolu Abant İzzet Baysal Üniversitesi Diş Hekimliği Fakültesine 2015-2023 yılları arasında başvuran hastaların KIBT görüntülerinden alınan morfometrik ölçümlerden kurulan makine öğrenmesi modelleri vasıtasıyla cinsiyetler arasında anlamlı farklılık olup olmadığını araştırdık.

Araştırmamızın başta Adli Tıp olmak üzere, Anatomi, Odontoloji, Antropoloji gibi muhtelif bilim dalına ve literatüre ışık tutacağı kanaatindeyiz.

2. GENEL BİLGİLER

2.1 Embriyoloji

Fetal yaşamın üçüncü haftasında gelişmeye başlayan paraksiyel mezoderm, nöral krest ve mezodermin lateral plağından köken alır. Gelişimi yetişkinlik döneminde büyüme plakalarımızın nihai kapanması ile sona erer. Bu süreç, mezenşim olarak bilinen ve sonunda hem kasların hem de kemiklerin geliştiği mesodermal farklılaşma süreci olarak isimlendirilir (17).

Kraniyal nöral krest hücreleri klavikula ve kraniyumda yer alan yassı kemikleri, mezodermin lateral plağı uzun kemikleri oluştururken, paraksiyel mezoderm iskeletin kalan kısmının tamamını oluşturmaktadır (18). Paraksiyel mezodermi, nöral tübün her iki yanında baş bölgesinde somitomer, oksipital bölgeden kaudale doğru ise somit olarak adlandırılan segmenter doku blokları meydana getirir. Somitler akabinde dorsolateral ve ventromedial olarak isimlendirilen parçalara bölünmektedir. Dördüncü haftanın bitiminde ise sklerotom hücreleri polimorf bir görünüm edinerek bağ dokusunu meydana getirmektedir. (19).

Oksipital somitler ve somitomerler kafatasının apeks ve basisinin oluşmasına katkıda bulunmaktadır. Membranöz ossifikasyon olarak bilinen bu süreç; kafatasının yassı kemiklerinde olduğu gibi, bazı kemikler de dermisteki mezenşimin direkt olarak kemiğe farklılaşmasıyla ortaya çıkmaktadır. Ancak kemiklerin büyük çoğunluğu, önce mezenşimal hücreler tarafından oluşturulan hiyalin kıkırdak şeklinde ortaya çıkmaktadır sonrasında ise kemikleşme gerçekleşmektedir (19). Fetal yaşamın 4. haftasında faringeal arklardan baş ve boynun dış hatları belirir (20).

Kafatası, beyni muhafaza eden neurocranium ve yüzün iskeletini meydana getiren viscerocranium olmak üzere iki bölümden oluşur (21).

Neurocranium, beyni çepeçevre saran yassı kemiklerden oluşan membranöz parça ve kafa tabanının kemiklerini oluşturan kıkırdağımsı parçadan meydana gelmektedir (22).

Yüz kemiklerinden oluşan viscerocranium ilk iki faringeal arkta gelişmektedir. Birinci faringeal ark ile gelişen kafatası yakından ilişkilidir. Maksiller çıkıntı birinci faringeal arkın dorsal kısmından gelişim gösterir. Bu yapıdan os maxilla, os zygomaticum ve os temporale'nin bir kısmı gelişmektedir. Birinci faringeal arkın ventral parçasından ise os mandibula'ya ait yapılar oluşmaktadır ve muhteviyatında Meckel kıkırdağını da bulunmaktadır. Meckel kıkırdağının çevresindeki mezenşim yoğunlaşıp kemikleşerek mandibulayı meydana getirir. Mandibular çıkıntının dorsal ucu; iki faringeal arkın dorsal

ucuyla birlikte incus, malleus ve stapedius isimli kemikçikleri oluşturmaktadır. Bahsi geçen kemikçikler insan vücudunda kemikleşme sürecini ilk önce tamamlayan kemikleridir (19).

Nazal kavitenin fetal yaşamdaki gelişimi altıncı haftadan itibaren başlamaktadır. Oronazal membranın yırtılması sonucunda nazal kaviteyi meydana getiren nazal kese çiftleri gelişir. Akabinde primer koana ve primer nazal kavite dorsal hat yönünde oluşmaya başlar. Septum nasale bu iki primer koana arasındaki dokulardan oluşmaktadır. Oral kavitenin lateral duvarından gelişen yassı çıkıntılar, kavite içerisinde kaudal yönde genişleyerek dilin üzerinde yatay bir pozisyon alırlar. Fetal yaşamın sekiz ve dokuzuncu haftalarında palatinum raflarının serbest kenarları, primer palatinum ve nazal septum birleşir. Böylece, oral kavite nazal septumdan ayrılır ve sekonder palatinum ile nazal septum birleşmesi tamamlanmış olur (23).

2.2 Anatomi

İnsan vücudu temel olarak baş-boyun, gövde ve ekstremitelere ayrılarak incelenmektedir. Aksiyel iskeleti, gövde ve baş-boyun iskeletinde yer alan kemikler oluşturmaktadır. Appendiküler iskelet ise gövde iskeletiyle bağlantı halinde olan üst ekstremit ve alt ekstremit kemikleridir. Yetişkin bir bireyde var olan 206 kemiğin, 126'sı appendiküler iskelette, 80 tanesi de aksiyel iskelette bulunur (24, 25).

Kafatası başı oluşturan kemik yapısıdır. Beyin için uygun bir boşluk oluşturur ve meninkslerle birlikte beyni muhafaza etmekle görevlidir. Kafatası; yüz, dişler, kraniyal sinirler, beyin, saçlı kafa derisi, beyin zarları, beyin omurilik sıvısı, duyu organları, kan damarları ve lenfatiklerini içerir. Beyinden gelişen 12 çift kraniyal sinir kafa iskeletinde mevcut olan ilgili deliklerden dışarı çıkmaktadır (26).

2.2.1 Kraniyum

Kraniyum 14 tanesi viscerocranium'a, 8 tanesi ise neurocranium'a ait olmak üzere toplamda 22 kemikten oluşmaktadır. 22 adet kemiğin birbirleriyle eklemler yaparak oluşturduğu kafa iskeletinin tamamına kraniyum denilmektedir. Bunlara 1 adet hiyoit kemik ile 3 çift kulak kemikçikleri de eklendiğinde 29 tane olurlar. Kraniyum kemiklerinin yapısını lamina interna ve lamina eksterna denilen kompakt kemik ve bu tabakaların arasını dolduran süngerimsi kemik meydana getirmektedir (27, 28).

Kraniyumu; frontal, sfenoidal, temporal, oksipital, etmoidal, pariyetal kemikler meydana getirmektedir. Üst kısmına calvaria, alt kısmına ise basis cranii denilmektedir (31). Beyin ve beyinciğin doldurduğu fossa cranii anterior, fossa cranii media ve fossa cranii posterior da basis cranii'de yer almaktadır (28).

Kraniyumda bu çukurlar dışında iç ve orta kulak boşlukları, burun boşluğu, göz çukuru ve paranasal sinüsler olmak üzere muhtelif büyüklükte birçok boşluk yer almaktadır (28).

Neurocranium, beyin ve beyinciği sarıp muhafaza eden kemiklerden oluşmaktadır. Os frontale, os parietale, os temporale, os occipitale, os sphenoidale, os ethmoidale'den meydana gelmektedir. Os temporale ve os parietale iki adet, diğer neurocranium kemiklerinden ise birer adet bulunmaktadır (29).

Os frontale, Şekil 2.1'de görüldüğü üzere alın bölgesini oluşturan kemiktir. Squama frontalis, pars orbitalis ve pars nasalis olmak üzere üç bölümü vardır (31). İçerisinde sinus frontalis isimli hava boşluğu mevcuttur. Önden os nasale ve os zygomaticum ile eklem yapmaktadır (30).

Margo supraorbitalis orbitanın üst sınır hattını oluşturmaktadır. Orbitanın dış duvarına dâhil olarak aşağı inerek eklem yapan uzantısının os zygomaticus ile eklem yaptığı görülür (31). Orbitanın tavanını oluşturan parça pars orbitalis olarak isimlendirilmektedir. Pars orbitalis'in medialinde fovea trochlearis, lateralinde fossa glandula lacrimalis olarak isimlendirilen çukurlar yer alır, glandula lacrimalis ise bu çukuru doldurmaktadır (27). Pars nasalis, margo supraorbitalisler arasında kalan ve burun boşluğunun tavanını oluşturan kısımdır. Nasion, os frontalis ve os nasalis'in birleştikleri orta noktaya verilen isimdir (31).

Os parietale kraniyumun üst yan kısmında yer alan, os frontalis'in arkasında iki taraflı olarak bulunan geniş ve yassı kemiktir. Bu kemik, os frontale, os sphenoidale, os temporale, os occipitale ve os parietale olmak üzere 5 kemik ile eklem halindedir (31, Şekil 2.2).

Os temporale'de işitme ve denge organlarıyla ilgili yapılar yer almaktadır. Bu kemik, kraniyumun yan ve alt kısımlarının da yapısına katılmaktadır (31). Pars squamosa, pars tympanica ve pars petromastoidea olmak üzere üç parçadan meydana gelmektedir (12).

Pars squamosa'nın alt kısmından öne doğru uzanan çıkıntı processus temporalis ile birleşerek arcus zygomaticus'u meydana getirmektedir (31). Os temporale'nin en küçük parçası pars tympanica'dır. Dış kulak yolu duvarlarının yapısına dâhil olmaktadır. Meatus acusticus externusun dışarıya açıldığı nokta burasıdır (28). Os occipitale ile os sphenoidale arasında bulunan piramit benzeri parçasına pars petromastoidea adı verilir (32).

Os occipitale, kraniyumun arkasında konumlanır. Pars basillaris, pars lateralis ve pars squama olmak üzere üç parçadan oluşmaktadır (32). Bu parçaların çevrelediği deliğe foramen magnum adı verilmektedir. Foramen magnum, cavitas cranii ile canalis vertebralis'i birbirine bağlar. Medulla spinalis, a. vertebralis, a. spinalis anterior, n. accessorius gibi hayati önem arz eden yapılar bu boşluktan geçmektedirler (67, Şekil 2.2).

Pars basillaris ossis occipitalis, foramen magnum'un ön kısmından başlayıp öne tarafa doğru uzanır. Pars basillaris'in ön yüzünde yer alan çukurlara clivus denir ve buraya medulla oblongata oturmaktadır. Alt yüzündeki çıkıntı ise tuberculum pharyngeum olarak isimlendirilir (31). Os occipitalis'in iç yüzünde bulunan çukurlardan fossa cerebellaris'e beyincik, fossa cerebialis'e ise oksipital lob konumlanmaktadır (28).

Os sphenoidale kraniyumun merkezinde yer almaktadır. Corpus, ala minor, ala major ve processus pterygoideus olmak üzere dört kısımdan oluşmaktadır. (12). Gövdesinin yanlarında bulunan kanatsız yapılardan küçük olanı ala minor, büyük olanı ise ala major olarak isimlendirilir. Corpus sphenoidale ile ala major'un birleşme noktasından başlayarak molar dişe uzanan çıkıntıya processus pterygoideus denir (31).

Corpus sphenoidale üzerinde yer alan oluk sulcus prechiasmaticus olarak isimlendirilir. Bu oluğun arkasında tuberculum sellae adlı bir tümsek mevcuttur ve arkasındaki boşluk fossa hypophysialis'tir. Hipofiz bezi bu boşluğa yerleşir. Tuberculum sellae, fossa hypophysialis ve dorsum sellae yapılarının tamamına sellae turcica adı verilmektedir (31).

Os ethmoidale, basis cranii'nin ön kısmında yer alır. Lamina cribrosa, lamina perpendicularis ve labyrinthus ethmoidale olmak üzere dört bölümden meydana gelmektedir (31). Lamina cribrosa, cavitas nasii'nin üst duvarının yapısına katılır. Lamina cribrosa'da yer alan foramina cribrosa'nın içersinden n. olfactorius geçmektedir. (28). Sağ ya da sol tarafa deviasyon gösterebilen lamina perpendicularis, septum nasinin büyük bir bölümünü meydana getirmektedir (31).

Labyrinthus ethmoidalis iki tabakadan oluşur. Bu tabakalar arasında çok sayıda hava boşluğu mevcuttur ve bu hava boşlukları etmoidal sinüs olarak adlandırılır. Labyrinthus ethmoidalis'in uzantıları olan concha nasalis superior ve concha nasalis media burnun dış duvarının yapısına katılırlar (28).

Viscerocranium; damak, çeneler ve dişleri de içeren, yüz bölgesinin iskeletini oluşturan kemiklerdir. Os zygomaticum, maxilla, os nasale, os lacrimale, os palatinum, concha nasalis inferior, vomer ve os mandibula'dan meydana gelmektedir. İnsan vücudunda vomer ve mandibula birer tane iken, diğer kemiklerden iki tanedir (28).

Os zygomaticus, yanak çıkıntısını ve orbitanın alt ve dış kenarını meydana getirmektedir. Kafa tabanı ve yüz bölgesi arasında destek vazifesi görür. Os frontale, os temporale, os sphenoidale ve maxilla ile eklem halindedir. Proc. temporalis adı verilen çıkıntısı proc. zygomaticus ile birleşerek arcus zygomaticus'u meydana getirmektedir (31, Şekil 2.1).

Maksilla, viscerocranium'da var olan temel kemiktir. Mandibula hariç yüz iskeletini oluşturan kemiklerin en büyüğüdür (31). Cavitas oris, cavitas orbitalis ve apertura piriformis'in yapısına katılmaktadır. Mandibula hariç bütün viscerocranium kemikleriyle eklem yapmaktadır. Corpus maxillae'da yer alan sinus maxillaris, en büyük paranasal sinüs olarak bilinir. Bu sinüs hiatus maxillaris vasıtası ile burun boşluğuna açılmaktadır (28).

Apertura piriformis'in yan duvarların büyük kısmını maksilla, üst kısmını ise os nasale oluşturmaktadır. Bu duvarı üstte lamina perpendicularis, altta vomer meydana getirir. Apertura piriformis'in alt kenarındaki spina nasalis anterior olarak adlandırılan dikensi uzantı maksillaların birleştiği noktada yer alır (31, 28).

Os lacrimale, ossa crani'nin en küçük ve naif kemiğidir. Os frontale, os ethmoidale, maksilla ve concha nasalis inferior ile eklem halindedir (31, Şekil 2.1). Os lacrimale'nin medial yüzü burun boşluğunun dış duvarının, lateral yüzü orbitanın iç duvarının yapısına katılmaktadır (28).

Os palatinum, Şekil 2.3'teki gibi maksilla ile sfenoid kemiğin processus pterygoideus'u arasında yer alır. Lamina horizontalis ve lamina perpendicularis denilen uzantıları mevcuttur. Os palatinum sert damak ile burun boşluğunun yapısına katılmaktadır (28).


Os nasale, os frontale'nin altında ve processus frontalis'lerin arasında yer alır. Apertura piriformis'in üst sınırını oluşturur (28). Sert damak ile nazal kavitenin yan duvarlarının, az da olsa orbita tavanının yapısına katılır (31). Os frontale ve os nasale'in kesiştikleri noktaya nasion denir (32).

Concha nasalis inferior burun boşluğunun dış duvarı boyunca uzanır. Yukarıdan aşağı doğru kendi üzerinde kıvrılmış şekildedir (31). Maksilla ve os lacrimale ile birlikte oluşturdukları kanala canalis nasolacimalis adı verilmektedir (28, Şekil 2.3).

Vomer, septum nasi'nin alt ve arka kısımlarının yapısına katılmaktadır (28). İki tarafında yer alan oluklar sulcus vomeris olarak adlandırılır, n. nasopalatinus bu oluklardan seyreder (31, Şekil 2.3).


Os mandibula, viscerocranium kemikleri içerisinde yer alan en büyük, en kompakt ve hareketli olan tek kemiktir. Gövdesine corpus mandibulae, çene eklemine katılan yan kısımlarına ise ramus mandibulae denir. Corpus mandibulae ve ramus mandibulae'nın birleştiği yerde oluşan açıya angulus mandibulae denilir (31, Şekil 2.1).

Skull: Anterior View




Şekil 2.1. Kraniyumun Önden Görünümü (33).

Skull
Lateral View



Şekil 2.2. Kraniyumun Yandan Görünümü (33).



Şekil 2.3. Kraniyumun Sagital Kesiti (33).

2.3 Paranasal Sinüsler

Burun boşluğunun etrafındaki içi havayla dolu boşluklara paranasal sinüsler denir. Paranasal sinüsler, vücudun en varyatif anatomik yapılarından biridir, dolayısıyla kişiler arası değişkenlik gösterebilmektedir. Burun mukozasının embriyonal dönemde burun boşluğunu oluşturan kemiklere gömülmesi sonucu oluşurlar (31). Çeşitli şekil ve boyutlardaki bu yapılar maksiller, etmoid, frontal ve sfenoid sinus olmak üzere dört çifttir. Komşu olduğu yapılar, konumları ve varyasyonlarının çokluğu nedeniyle klinik açıdan önem arz ederler (34).

Sesin rezonasyonunda, beyin ısısının korunmasında ve travmalara karşı muhafazasında, kraniyum kemiklerinin yükünü hafifleterek dengeyi sağlamada vazife alırlar (32).

2.3.1 Frontal Sinüs

Frontal sinüs, gelişimi en geç başlayan sinüstür. Yenidoğanda oldukça küçük olup 7-12 yaşlarında genişleyerek belirgin hale gelmektedir (34). Ergenlik dönemine dek büyümeye devam eder ve ergenlikten sonra gelişimi durur. İlerleyen dönemlerde atrofiye uğrayarak değişebilirler (35).

Frontal sinüsler Şekil 2-4'te görüldüğü gibi; os frontale'nin laminaları arasında, arcus superciliaris'lerin derininde ve burun tavanında yer almaktadır (32). Frontal sinüs, septum intersinuale frontale olarak adlandırılan yapı ile ikiye ayrılır. Septum intersinuale, frontale deviasyonlarından dolayı sağ ve sol taraftaki boşluklar eşit büyüklükte değildir. (31).

Frontal sinüsler, meatus nasi medius'a ductus frontonasalis denilen kanallar vasıtasıyla açılırlar (28). Bu sinüsler a. supraorbitalis ve a. ethmoidales anterior tarafından beslenir ve v. supraorbitalis ile v. ophtalmica superior tarafından drene edilir (31, Şekil 2.4).

2.3.2 Maksiller Sinüs

Maksiller sinüs, yenidoğanda 3-4 mm genişlikte, 7 mm uzunlukta olup, hacmi yaklaşık 6-8 ml'dir. Yaklaşık on yedi yaşında hem kadın hem erkekte maksiller sinüs pnömatizasyonu, sinüs tabanının burun seviyesinin altına inmesiyle sonlamaktadır. Yetişkin bireylerde boyutu yaklaşık 25x38x36 mm, hacmi ise 15-20 ml'dir (36).

Maksiller sinüs, paranasal sinüsler arasında oluşmaya ilk başlayan ve en büyük olan sinüstür. Maksilla'nın gövdesinde bulunur ve piramit şeklindedir. Basişi nazal kaviteye, apeksi proc. zygomaticus'a yönelmiştir (31). Ostium sinus maksillaris aracılığıyla burun boşluğuna açılmaktadır (28, Şekil 2.4).


2.3.3 Etmoidal Sinüs

Nazal kavite ve orbita arasında yer alan küçük boşluklardan meydana gelmektedir. Büyük kısmı labyrinthus ethmoidalis'te yer alır ve cellulae ethmoideae anteriores, cellulae ethmoideae mediae, cellulae ethmoideae posteriores olmak üzere üç ayrı grupta incelenir. Her bir grupta yaklaşık 3 adet büyük 15-18 adet küçük hava odacığı mevcuttur (31, 28, Şekil 2.4).

2.3.4 Sfenoidal Sinüs

Sfenoit kemiğin gövdesinde yer alan bir çift boşluktur. Septum intersinuale sphenoidale, sfenoit sinüsleri birbirinden ayıran duvardır. Sfenoit sinusler ön kısımda bulunan recessus sphenothmoidalis'e açılır. Pons, hipofiz ve sinus cavernosus ile komşuluğu bulunmaktadır (31, Şekil 2.4).

A



© Elsevier Ltd. Drake et al: Gray's Anatomy for Students www.studentconsult.com

Şekil 2.4. Paranasal Sinüsler (37).

2.4 Nazal Kavite

Nazal kavitenin üst duvarını oluşturan yapılar; os nasale, os frontale'ye ait spina nasalis, os ethmoidale'ye ait lamina cribrosa ve os sphenoidale'nin corpus kısmıdır. Tabanını ise maksillaya ait proc. palatinus ve os palatinum'a ait lamina horizontalis meydana getirir. Lateral duvarını konkalar ve bu konkalar arasında bulunan boşluklar oluşturur. Nazal septum tarafından iki bölmeye ayrılmaktadır. Nazal septum her bir bölmenin medial duvarını meydana getirir. Nazal septumun arka alt kısmını vomer, arka üst kısmını os ethmoidale'ye ait lamina perpendikularis oluşturur. Ön üst kısmını ise septum cartilage meydana getirir. Nazal kavite ön bölgede burun delikleri ve regio vestibularis'ten başlayıp arka bölgede koanalar ve nazofarenkse açılarak sonlanır (38).

2.5 Cinsiyet Tahmini ve Yöntemleri

Yaşamakta olan yahut ölmüş bireylerin kimlik olarak adlandırılan ayırt edici özellikleri kullanılarak tespit edilmesine kimliklendirme denmektedir. Adli kimlik; kişinin nüfus kâğıdında yazılı olan kimliğidir. Tıbbi kimlik ise kişinin dış görünüşünün tarifidir (39).

Cinsiyetin belirlenmesi, tecavüz, boşanma, kitlesel afetler ve cesetlerin kimliklendirilmesi gibi adli vakalarda son derece önemlidir (40). Cinsiyetin belirlenmesi şüpheli sayısını yarıya düşürdüğü için yaşın belirlenmesine nazaran daha önemlidir (41). Cinsiyetin doğru bir şekilde tahmin edilmesi yaş, ırk ve boy tahmininde referans teşkil ettiği için hayati öneme sahiptir (13).

Benler, yaralar, dövme izleri, iskelette görülen herhangi bir anormali yahut deformite, ölümden önce ve ölümden sonra karşılaştırılmasına yardımcı olmaktadır (42,43).

Kemiklerin incelenmesi ve anatomik ölçümleri kökenleri hakkında rehberlik etmekle birlikte; cinsiyetleri, boyları ve ölüm yaşları hakkında da bilgi vermektedir. Adli antropologlar bu nedenle ölüm araştırmalarına dâhil olmaktadır ve kişinin, ölüm nedeninin ve ölüm şeklinin belirlenmesine görev almaktadırlar (44).

Puberte öncesi iskeletin morfolojik özellikleri ile cinsiyetini tahmin etmenin oldukça zor olduğu belirtilmiştir. Puberte öncesi dönemde iskelet morfolojisinde tam anlamıyla ortaya çıkmamış cinsiyet farklılıkları nedeniyle, yetişkin iskeletinin cinsiyeti yenidoğan veya genç bir iskelete kıyasla daha güvenilir bir şekilde tespit edilmektedir. (42, 43, 45).

Pelvisin ardından kafatasının, metrik veya morfolojik yöntemler kullanılarak cinsiyetin tespit edilmesinde en güvenilir bölge olduğu bildirilmektedir. (46).

Cinsiyet tahmininde kullanılan yöntemler, morfolojik veya metrik yöntemler olarak gruplandırılır. Bu yöntemler, gelişen moleküler tekniklere ve başarısına rağmen, tanımlama sürecinde elzemdir (47). Moleküler yöntemler oldukça karmaşık olmakla birlikte yüksek düzeyde beceri ve kompleks ekipmanlar gerektirmektedir. Bu yöntemlerin güvenilirliği daha yüksektir ancak teferruatlı, oldukça pahalı ve zaman alıcıdır (49, 50).

Cesedin herhangi bir şekilde deforme olması cinsiyete özgü morfolojik özellikleri tespit etmeyi neredeyse imkânsız hale getirmektedir. Cinsiyet belirleme aşamasında, yeni osteometrik yöntemler sayesinde yüksek doğruluk elde edilebilmektedir. Fakat eksik kısımları olan yahut kötü bir şekilde parçalanmış kemiklerde tespit edecek kadar yeterli bilgiyi sağlayamıyorsa, morfolojik yöntemlerin yanı sıra moleküler metotlardan yardım almak mecburidir (50).

Morfolojik yöntemler, cinsiyete özgü özelliklerin görsel açıdan değerlendirilmesine dayalıdır. Hızlı bir ön değerlendirme verir fakat bu şekilde çoğunlukla öznel veriler elde edilmektedir (47, 48).

Morfolojik gözlemler yöntem açısından kolay olmasının yanı sıra vücut yapısını etkileyen; beslenme şekli, meslek, ırk ve coğrafi köken gibi faktörler göz önüne alındığında değerlendirilmesi daha zordur. Morfolojik değerlendirme, sağlam kemiklerle daha güvenilir sonuçlar vermekte iken, parçalanmış kemikler veya iskelet kısımları eksik olduğunda doğruluk dereceleri azalmaktadır (49).

Metrik yöntemler, cinsiyetler arasındaki değişkenlerin sayısal veriler halinde değerlendirilmesi esasına dayanır. Bu yöntemler verileri, çoğunlukla farklı istatistiksel

yöntemler ile birlikte kullanılarak ortaya koyar. Metrik çalışmalardan elde edilen sayısal verilerin değerlendirilmesi ve yorumlanması daha kolaydır (49).

BT ve manyetik rezonans görüntüleme (MRG), geleneksel yöntemlerin sistematikleşmesini ve tekrar değerlendirilmesine olanak tanıyan, hayati role sahip olan yöntemlerdir. Bu yöntemlerin cinsiyet belirlemede doğruluk oranı oldukça yüksektir. Son yıllarda BT ve benzeri üç boyutlu (3B) görüntüleme yöntemlerinin kullanımı yaygınlaşmıştır (51).

İnsan vücudu 3B medikal görüntüleri görselleştirerek incelenebilmekte ve bu teknik artık klinik uygulamalarda önemli bir görev üstlenmektedir (52, 53). BT ve MRG tarayıcıları gibi tıbbi görüntüleme cihazları ve teknikleri geliştikçe, insan vücudu daha teferruatlı halde gözlemlenebilmektedir.

KIBT özellikle odontoloji alanında dental yapıları incelemek için kullanılsa da maksillofasiyal alanda paranasal sinüsler, maksilla, mandibula, temporal kemik, paranasal sinüsler gibi sert dokulara ait anatomi, varyasyon ve patolojilerin incelenmesine olanak sağlar. Bu yöntemin, BT'ye nazaran radyasyon dozunun az olması, MRG ye nazaran görüntü elde etme ve yorumlamasının kolay olması gibi avantajları mevcuttur (54). Günümüzde yaygın kullanılan KIBT görüntülerinin adli tıp alanında kullanıldığı, yaş ve cinsiyet tayininin yapıldığı pek çok çalışma mevcuttur (55, 56, 57).

Geometrik morfometrik analiz ise geleneksel yöntemlerle tayin edilemeyen ve çoğunlukla önemsiz olmayan eğrilere ve çıkıntılara sahip yapıların morfolojisini incelemek amacıyla kullanılmaktadır. (58, 59).

İskelet deformasyonu ile paralel olarak, kimi zaman morfolojik veya morfometrik metotlarla cinsiyet tayini olanaksız hale gelmektedir. Bu durumlarda araştırmacı moleküler yöntemlere yönelerek iyi bir alternatif oluşturabilir (60).

2.6 Yapay Zekâ ve Makine Öğrenmesi

Ünlü İngiliz mantık ve matematikçisi Alan Mathison Turing 1950 yılında "Makineler düşünebilir mi?" sorusu ile makine zekâsını tartışmaya açmıştır. Bilgisayar biliminin "babalarından biri" olarak kabul edilen Turing, hesaplamanın matematiksel bir modeli olan evrensel makineyi tanımlamıştır (61).

Yapay zekâ; "zeki davranış" olarak adlandırılan şeyin bilişimsel anlamı ve bu tür davranışları sergileyen ürünlerin meydana getirilmesiyle ilgilenen bilim dalıdır. Bu kavram genellikle insanların bilişsel eylemleri taklit eden makineleri tanımlamak için kullanılır. Bilgisayar yahut bilgisayar kontrolündeki bir robota, insan yeteneklerine benzer faaliyetleri yerine getirtmeyi amaçlar (62).

Makine öğrenmesi yapay zekâ çalışmalarının büyük bir parçası ve alt alanıdır. Makine öğrenmesi terimi ilk kez Arthur Samuel tarafından 1959 yılında kullanılmıştır (64). Önceki verileri kullanarak gelecek için tahminlerde bulunmak amacıyla makine öğrenmesi yöntemleri geliştirilmiştir (63). Makine öğrenmesi sayesinde veriler üzerinden istatistiksel ve matematiksel yöntemler ile model oluşturmak hedeflenmektedir. Makine öğrenmesi bu modeller vasıtasıyla incelenen verilerden, çıkarımlar yapar ve tahminde bulunur. (62).

Yapay zekâ yöntemlerinin kullanımı ile hayatın çoğu alanında gelişmeler meydana gelmiştir. Bu alanların başında sağlık sektörü yer alır. Dijital sağlık verilerindeki aşırı büyüme, sağlık verilerinin sürekli artış halinde olması ve dijitalleşmesi, bu verilerin makineler aracılığı ile analiz edilmesi gerekliliğini düşündürmektedir. Makine öğrenmesi sayesinde kanıta dayalı olarak daha kesin sağlıklı sonuçlara ulaşıldığı çalışmalarda gösterilmiştir (65, 66).

Makine öğrenmesinde bir veri girilir ve buna uygun çıktıları tahmin edebilmesi amaçlanır. Bu doğrultuda veri grupları üzerinde bir algoritma eğitimi gerçekleştirilir. Makine öğrenmesi kapsamına çok fazla algoritma türü mevcuttur. Kullanılacak algoritma beklentiye, problemin kaynağına ve veri sayısına göre değişkenlik gösterir. Özgüllük ve duyarlılık değerlerine ya da doğruluk skoruna bakılarak en iyi sonucu veren algoritma tespit edilebilmektedir. En iyi neticeyi veren algoritma tercih edilerek sonuç iyileştirilmektedir. Bu sayede iş yükü ve zaman maliyeti azaltılabilmekte ve verimlilik artırılabilir, görüntüler daha hızlı ve güvenilir şekilde rapor edilebilmektedir (52, 68).

Veri setinin bir bölümü algoritmanın eğitiminde, eğitim verisi kullanılırken bir kısmı ile algoritmanın performansını değerlendirmek amaçlı test verisi olarak kullanılır. Çoğu zaman veri setinin %20'si test amaçlı, %80'i eğitim için kullanılmaktadır. (62).

Makine öğrenmesi denetimli, denetimsiz ve pekiştirmeye dayalı öğrenme olmak üzere üç gruba ayrılmaktadır (62, 69).

Denetimli öğrenme; algoritmalarından edinilen verilerden alınan etiketli örneklerden yola çıkarak tahmin yapmaktadır. Sonucun az çok tahmin edilebildiği durumlarda kullanılan bu teknik, sınıflandırma ve regresyon olmak üzere iki ana kategoriye ayrılmaktadır. Sınıflandırma, kategorik değişkenlerin etiketlerini bulmayı amaçlarken, regresyon gözlem noktalarının etiket değerini tahmin etmeye çalışmaktadır (69, 70).

Lojistik Regresyon (LR), denetimli öğrenme tekniği kapsamında yer alan, sıklıkla tercih edilen makine öğrenmesi algoritmalarından biridir. Değişkenler arasında var olan bağımlılık ilişkisini tespit etmek için kullanılır (71). Lineer Regresyon Analizinde bağımlı değişkenin değeri, Lojistik Regresyon Analizinde ise bağımlı değişkenin alabileceği

değerlerden birinin gerçekleşme olasılığı tahmin edilir. Ayrıca bağımsız değişkenin çoklu normal dağılım göstermesi şartı aranmaz (72). Yine de kullanımı ile ilgili bazı varsayım ve gereklilikler bulunmaktadır. Verilerde kayıp ve uç değerler incelenmelidir. Bağımsız değişkenler arasındaki yüksek korelasyona oldukça duyarlıdır. Varlığı durumunda faktör analizi ile gruplandırılmaları ya da modelden çıkarılmaları önerilmektedir. Ayrıca bağımsız değişkenler ile sonuç değişkenin logit değeri arasında doğrusal ilişki olduğunu varsayar (73).

Destek Vektör Makinesi (SVC), Vapnik ve ekibi tarafından geliştirilmiştir. Regresyon ve sınıflandırma problemlerinde kullanılmaktadır. Eğitim verileri sayesinde nesneleri doğru bir şekilde sınıflandırmayı amaçlar. Sınıflar arasında bir karar sınırı belirler, bu şekilde verileri ayırma işlemini gerçekleştirmiş olur (74). Kullanılacak veri miktarı bir önemi arz etmemektedir (75, 76).

Gaussian Naive Bayes algoritması (GNB), verilen ön bilgi ile yeni bir verinin ait olduğu olasılığını hesaplamaktadır. Bu yöntemde niteliklerin birbirinden bağımsız olduğu varsayılmaktadır. Çalışma mantığı şu şekildedir: Veri kümesinde yer alan her veri için her ihtimalin olasılığını ayrı ayrı hesaplamak ve ortaya çıkan sonuçtan olasılık değeri en fazla olana göre gruplandırmayı gerçekleştirmek (77, 78).

Karar Ağacı (DT), denetimli öğrenme algoritmaları ailesine mensup bir algoritmadır. Diğer denetimli öğrenme algoritmalarından farkı, sınıflandırma ve regresyon problemlerini çözmek için de kullanılabilir olmasıdır. Karar Ağacında amaç; eğitim verilerinden edinilen basit karar kurallarını öğrenmek, bu bilgiyle hedef değişkenin sınıfını değerini ya da sınıfını tahmin etmek için eğitim modeli meydana getirmektir. Yorumlanması kolay bir algoritmadır çünkü kararlara ve kararların açıklamalarına yer vermektedir. Ağacın yapraklarını gruplandırılmış sınıflar oluşturur. Ağacın dallarını ise sınıflandırma verileri üzerinde yer alan işlemler oluşturmaktadır (62).

Karar Ağaçları baz alınarak geliştirilen Rastgele Orman (RFC), hem sınıflandırma hem de regresyon amacıyla kullanılabilir. Bir ağaç oluşturmak yerine bir orman oluşturup, bu ormandaki ağaçları rastgele düzenlemektedir. (78, 79). Aşırı uyum sorununu çözmek amacıyla veri setini ve öznelilikleri farklı parçalara böler, tahminlerin ortalamasını alır ve bu şekilde daha doğru sonuçlar elde etmeye çalışır. RF modeli, gruplar arasındaki ilişkilerin çözümlenmesinde kullanılmakta olan başarılı bir yöntemdir (13).

K-En Yakın Komşu (KNN), veri içerisinde yer alan noktaları kendine en yakın noktalarla karşılaştırılarak veri kümeleri oluşturulmayı hedeflemektedir. KNN, sınıflandırma problemlerinde kullanılan, parametrik olmayan bir algoritmadır. Bu algortmada amaç, yeni oluşturulan noktaya en yakın, önceden belirlenmiş sayıda eğitim örneğini bulmak ve etiketi

buradan yola çıkarak tahmin etmektir. Sınıflandırmayı verilen k değerince en yakın komşunun sınıfına göre gerçekleştirir. K-En Yakın Komşu algoritmasında bir vektörü sınıflandırılma işlemi, sınıfı bilinmekte olan vektörler vasıtasıyla yapılmaktadır. Veriler arasındaki aralığı tayin etmek için Manhattan, Öklit gibi ölçütler kullanılmaktadır (80). Hesap edilen mesafe yüksek çıkarsa veriler arası benzerlik oranı düşer. Ölçülen mesafenin düşük çıkması ise toplanan verilerin benzerlik oranını arttırır (78).

Denetimsiz öğrenmede veri noktalarında etiketlenme yapılmamaktadır. Algoritma, verileri düzenler veya bunların yapısını açıklar. Bu şekilde veri noktalarında etiketleme gerçekleştirir. Bu teknik, sonucun tahmin edilemediği durumlarda kullanılmaktadır. Sağlık alanında hastalıkların benzer özelliklere göre gruplandırılmasında tercih edilebilir bir yöntemdir (62, 78).

Pekiştirmeye dayalı öğrenmede, sonuçlardan öğrenim sağlayan ve gerçekleştirilecek eyleme karar veren algoritmalar kullanılmaktadır. Bilgisayar oyunları bu öğrenme çeşidine örnek verilebilir (62, 78). Deneme yanılma yöntemiyle kendisini eğitmeye maruz bırakılan algoritma, her yeni durumda belirli bir davranış kalıbıyla teşvik edilir veya cezalandırılır (78).

Denetimli veya denetimsiz öğrenme algoritmalarını başlatmak için eğitim sürecine başlamadan evvel, parametre değerlerine ihtiyaç vardır. Hiperparametre olarak adlandırılan bu parametrelerin, oluşturulacak modele etkisi büyük olabilir. Hiperparametreler; öğrenme oranı, Kernel parametreleri, ağ mimarisi gibi bir öğrenme algoritmalarının sonuçlarını yapılandırmak için kullanılır. Hiperparametrelerin optimize edilerek belirlenmesi, oluşturulacak modelin başarı oranını arttırmak için elzemdir (71, 81, 82).

3. GEREÇ VE YÖNTEM

Bu çalışmaya retrospektif olarak, Bolu Abant İzzet Baysal Üniversitesi Diş Hekimliği Fakültesine 2015-2023 yılları arasında başvuran, dâhil edilme kriterlerine uyan 344 erkek 408 kadın toplamda 752 hasta çalışmaya alındı. I-CAT 3D (Imaging Sciences International, Hatfield, PA) cihazıyla çekilen konik ışınli bilgisayarlı tomografi görüntüleri, bilgisayar ortamına aktarılıp I-Cat Vision programı ile mimimetrik ölçümler alındı. Mevcut görüntüler; görüntüleme alanı 16x6-10 cm; voksel boyutu 0.3 mm³; 120 kVp, 7mA, ışınlama süresi 4.8 saniye ışınlama parametreleri kullanılarak elde edildi.

Çalışmaya Bolu Abant İzzet Baysal Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulundan alınan, 02.04.2024 tarih ve 87 sayılı yazılı izin ile başlandı ve araştırma boyunca tüm etik kurallara uyuldu.

Herhangi bir nedenden dolayı artefaktı olan, incelenecek yapıların görüntüleme alanına girmediği görüntüler, ortodontik tedavi gören, ilgili bölgede travma, lezyonu ve diş kaybı olan 1348 adet hasta görüntüsü çalışmaya dâhil edilmedi.

Ölçümler I-Cat Vision programında; Dell Inspiron marka 1506 inch bilgisayar ile koronal kesitler üzerinde maksiller sinüslerin, nazal kavitenin ve zigomatik arkın en geniş sınırlarının izlendiği kesit üzerinde milimetre (mm) cinsinden yapılmıştır. Yapılan morfometrik ölçümler şu şekildedir:

Maksiller sinüs genişliği (MSD): Maksiller sinüslerin mediolateral yönde en dış iki noktasından geçen birbirine paralel iki doğru arasındaki mesafe (Şekil 3.1)

Maksiller sinüs uzunluğu (MSH): Maksiller sinüslerin superioinferior yönde en dış iki noktasından geçen birbirine paralel iki doğru arasındaki mesafe (MSH) (Şekil 3.2)

Nazal kavite genişliği (NCD): Nazal kavitenin mediolateral yönde en dış iki noktasından geçen birbirine paralel iki doğru arasındaki mesafe (Şekil 3.3)

Nazal kavite uzunluğu (NCH): Nazal kavitenin superioinferior yönde en dış iki noktasından geçen birbirine paralel iki doğru arasındaki mesafe (Şekil 3.4)

Zigomatik ark genişliği (ZAD): Zigomatik arkın mediolateral yönde en dış iki noktasından geçen birbirine paralel iki doğru arasındaki mesafe (Şekil 3.5)


Zigomatik ark uzunluğu (ZAH): Zigomatik arkın superioinferior yönde en dış iki noktasından geçen birbirine paralel iki doğru arasındaki mesafe (Şekil 3.6)




Şekil 3.1. Maksiller Sinüslerin En Geniş Yerinden Mediolateral Ölçümü.



Şekil 3.2. Maksiller Sinüslerin En Uzun Mesafeden Superoinferior Ölçümü.



Şekil 3.3. Nazal Kavitenin En Geniş Mesafeden Mediolateral Ölçümü.



Şekil 3.4. Nazal Kavitenin En Uzun Mesafeden Superoinferior Ölçümü.



Şekil 3.5. Zigomatik Arkın En Geniş Yerinden Mediolateral Ölçümü.




Şekil 3.6. Zigomatik Arkın En Uzun Mesafeden Superoinferior Ölçümü.

Ölçümler maksiller sinüs ve zigomatik ark için sağ ve solda ayrı ayrı; nazal kavitede ise sağ ve sol yarısında yapılarak kaydedilmiştir. Tüm ölçümler tek bir gözlemci tarafından yapılmıştır.

Elde edilen ölçümlerden temel istatistiksel metotlarla makine öğrenme algoritmalarının girişinde kullanılacak değişkenler tayin edildi. Verilerin normal dağılıma uygunluğu Shapiro-Wilk testi ile analiz edildi. Normal dağılıma uyan değişkenlerin tanımlayıcı istatistikleri minimum (Min), maksimum (Max), ortalama (Ort) ve standart sapma (SD) ile gösterilirken normal dağılıma uymayan değişkenlerde ortanca ve çeyrekler arası aralık kullanıldı. Parametrelerin cinsiyetler arası farklılığı Student's t testi ile analiz edildi. Arada istatistiksel farklılık bulunmayan veriler çıkarıldıktan sonra cinsiyet ile arasında düşük ($\leq 20\%$) ya da yüksek ($\geq 80\%$) korelasyon bulunan değişkenlerin dışlanması için Pearson korelasyon testi yapıldı. Kriterleri sağlayan değişkenlerden geri yayımlı Lojistik Regresyon modeli kuruldu. Model sonucunda anlamlı olduğu saptanan parametreler 0,2 test ve 0,8 eğitim verisi olacak şekilde rastgele bölündü ve Lojistik Regresyon, Lineer Diskriminant Analizi, Karar Ağacı, Rastgele Orman Sınıflandırma, K-En Yakın Komşu, Destek Vektör Makinesi ve Gaussian Naive Bayes algoritmaları eğitildi. En iyi hiperparametre on katlı çapraz doğrulama ve doğruluk skoruna göre belirlendi. Analizler en iyi hiperparametre ile tekrarlandı. Makine öğrenmesi algoritmalarının tahminlerinin doğruluk skoru Lojistik Regresyon modeli ile karşılaştırılarak en etkin algoritma belirlendi. Aynı zamanda analiz süreleri ölçüldü. Analizlerin yapımında ve algoritmaların eğitiminde Python 3.8.8 derleyicisi ve Jupyter Notebook 6.4.6 editörü kullanıldı. Anlamlılık seviyesi $p < 0,05$ olarak belirlendi.


4. BULGULAR

Retrospektif olan bu çalışmamızda, Bolu Abant İzzet Baysal Üniversitesi Dış Hekimliği Fakültesine 2015-2023 yılları arasında başvuran, dâhil edilme kriterlerine uygun olan 344 erkek (%46), 408 (%54) kadın toplamda 752 hastaya ait görüntüler incelendi (Şekil 4.1).




Şekil 4.1. Cinsiyete Göre Sayım Grafiği.

Sağ tarafta yapılan ölçümlere ait histogram grafiği Şekil 4.2’de yer verildi. Buna göre MSD daha dar bir alanda yayılım gösterirken, MSH daha geniş bir alana yayılmaktaydı. NCD’nin histogram grafiğine bakıldığında 11 mm ile 15 mm arasında bir sıklık söz konusuydu. NCH sıklığı ise 27 mm ile 35 mm arasında daha sık olarak gözlemlendi. ZAD daha dar bir alana yayılım göstermekte iken, ZAH daha geniş bir alana yayılım gösterdi.



Şekil 4.2. Sağ Tarafta Yapılan Ölçümlere Ait Histogram Grafiği.

Sol tarafta yapılan ölçümlerden elde edilen verilere ait histogram grafiği Şekil 4.3'te yer almaktadır. Buna göre MSH ve MSD birbirine yakın bir dağılım gösterdi. NCD daha dar bir alana yayılıyorken, NCH daha geniş bir alana yayıldığı gözlemlendi. ZAD, ZAH'ye nazaran çok daha dar bir alanda yayılım gösterdi.



Şekil 4.3. Sol Tarafta Yapılan Ölçümlere Ait Histogram Grafiği.

Verilerin normal dağılıma uygunluğu Shapiro-Wilk Testi ile teyit edildi. Analiz sonucuna göre; değişkenlerin tamamının normal dağılıma uymadığı görüldü. İstatistik ve p değerlerine Tablo 4.1'de yer verildi.

Tablo 4.1. Shapiro-Wilk Analizi Sonuçları.

Değişkenler	İstatistik	Sig.
Yaş	0,964	<0,001
RMSH	0,991	<0,001
RNCH	0,988	<0,001
RNCD	0,987	<0,001
RZAH	0,99	<0,001
RZAD	0,942	<0,001
LMSH	0,996	0,028
LNCH	0,991	<0,001
LNCD	0,986	<0,001
LZAH	0,989	<0,001
LZAD	0,982	<0,001


Değişkenlerin gruplar arası farklılıklar Mann-Whitney U Testi ile analiz edildi ve sonuçlar Tablo 4.2'de verildi. Tanımlayıcı istatistikler minimum, maksimum, ortanca ve çeyrekler arası açıklık değerleri ile gösterildi.

Yaş değişkeninin ortanca değeri kadınlarda 42,0 iken erkeklerde 44,5 olarak bulundu. Çeyrekler arası aralık kadınlarda 20,0 erkeklerde 20,25 olarak tespit edildi. Her ne kadar erkeklerin ortanca değeri daha yüksek bulunsada aradaki bu fark istatistiksel olarak gösterilemedi.

Cinsiyetler arası tanımlayıcı istatistiklere bakıldığında ortanca değer; LMSD, LMSH, LNCD, LZAD, RNCH, RNCD, RZAH, RZAD erkeklerde; LNCH, LZAH, RMSD, RMSH değişkenleri ise kadınlarda daha yüksek bulundu. Maksimum değerler; LNCD ve LZAD değişkenleri kadınlarda, diğer değişkenler ise erkeklerde daha yüksek tayin edildi. Minimum değerler; RNCH değişkeninde kadınlar ve erkeklerde eşit bulundu. LZAH değişkeni erkeklerde daha düşük iken, diğer değişkenlerinin kadınlarda daha düşük olduğu görüldü. Yaş dışındaki değişkenlerin tamamında cinsiyetler arası farkın istatistiki olarak anlamlı olduğu görüldü. Analiz sonuçları Tablo 4.2’de kutu grafiği ise Şekil 4.4’te verildi.


Tablo 4.2. Parametrik Olmayan Değişkenlerin Tanımlayıcı İstatistikleri.

CİNSİYET	KADIN				ERKEK				U	Sig.
	Ortanca	ÇAA	Min.	Max.	Ortanca	ÇAA	Min.	Max.		
Yaş	42,0	20,0	18,0	20,0	44,5	20,25	18,0	65,0	66409,5	0,204
RMSD	24,6	3,7	18,3	34,2	30,9	4,8	17,8	42,4	14285,5	<0,001*
RMSH	31,0	5,4	21,0	44,0	37,7	6,3	22,6	49,0	22692,5	<0,001*
RNCH	29,1	3,9	21,6	42,0	31,5	4,5	21,6	47,1	45932,0	<0,001*
RNCD	13,2	2,4	8,7	20,8	14,0	2,1	9,7	19,0	55502,0	<0,001*
RZAH	25,5	5,4	16,7	43,0	27,9	4,225	18,0	46,2	45651,0	<0,001*
RZAD	4,85	1,5	2,4	10,0	6,0	1,2	3,3	16,3	33836,5	<0,001*
LMSD	24,3	3,4	17,7	35,0	30,6	5,1	16,5	39,3	16218,0	<0,001*
LMSH	31,8	4,825	20,4	43,0	37,55	5,1	23,1	48,0	22713,5	<0,001*
LNCH	29,85	4,225	21,0	43,1	32,1	4,3	23,1	48,0	44691,0	<0,001*
LNCD	13,4	1,8	7,82	20,4	14,0	2,025	10,5	19,2	51925,0	<0,001*
LZAH	26,1	5,0	16,8	43,0	28,8	4,025	15,9	45,0	44269,5	<0,001*
LZAD	5,05	1,5	2,4	11,0	6,3	1,2	3,5	10,0	31370,0	<0,001*



Şekil 4.4. Değişkenlere Ait Kutu Grafiği.

Makine Öğrenmesi algoritmalarında kullanılacak olan modellerin belirlenmesinde Lojistik Regresyon Analizi kullanıldı. Mann-Whitney U Testi sonrasında erkeklerle kadınlarda istatistiksel açıdan anlamlı olarak farklı olduğu görülen bağımsız değişkenlerin arasındaki korelasyona bakıldı. En yüksek korelasyonun LMSD ve RMSD arasında 0,797 olduğu görüldü. En düşük korelasyon oranı ise LMSD ve LNCH değişkenleri arasında 0,1 idi. Önerilen >0,90 barajını geçen değişken olmadı. Buna dayanarak sağ, sol ve bilateral olmak üzere üç model kuruldu. Analiz sonuçlarını gösteren ısı haritası Şekil 4.5’te verildi.



Şekil 4.5. Değişkenlerin Korelasyonlarını Gösteren Isı Haritası.

Uç değerler Mahalonobis Uzaklığı ile belirlendi ve gerekli düzenlemeler yapıldı. Sol taraftan alınan ölçümlerden kurulan modelden uç değerler çıkarıldıktan sonra tanımlayıcı istatistiklere tekrar bakıldı ve Mann-Whitney U Testi yenilendi (Tablo 4.3).

Tablo 4.3. Mann-Whitney U Testi

Cinsiyet	Erkek				Kadın				U	Sig.
	Median	ÇAA	Min.	Max.	Median	ÇAA	Min.	Max.		
LMSD	30,6	5,1	16,5	39,3	24,3	3,4	17,7	35,0	122368,0	<0,001*
LMSH	37,5	5,1	23,1	48,0	31,8	4,8	20,4	43,0	115815,0	<0,001*
LNCD	14,0	2,1	10,5	19,2	13,4	1,8	9,9	20,4	86553,0	<0,001*
LZAD	6,3	1,2	3,5	10,0	5,0	1,5	2,4	7,8	107715,5	<0,001*

Bağımsız değişkenler ile sonuç değişkenin logit değeri arasındaki doğrusallık elde edilen yeni veriler kullanılarak Box-Tidwell dönüşümü ile test edildi (Tablo 4.4).

Tablo 4.4. Box-Tidwell Transformasyonu Sonrası Klasifikasyon Tablosu.

	B	df	Sig.
LMSD	8,342	1	<0,001*
LMSH	3,839	1	0,015
LNCH	-0,959	1	0,619
LNCD	-2,63	1	0,422
LZAH	0,608	1	0,688
LZAD	-2,483	1	0,4
LMSD by LN_lmsd	-2,034	1	<0,001*
LMSH by LN_lmsh	-0,893	1	0,011
LNCH by LN_lrch	0,223	1	0,607
LNCD by LN_lncd	0,629	1	0,482
LZAH by LN_lzah	-0,143	1	0,685
LZAD by LN_lzad	0,607	1	0,575
Constant	-42,975	1	0,066

Sol taraftan alınan ölçümlerde varsayımı sağlamayan LMSD ve LMSH değişkenleri analizden çıkarıldı. Diğer modellere sabit değer eklenmesi dışında bir değişiklik yapılmadı ve Lojistik Regresyon Analizine gidildi. Analiz sonuçları Tablo 4.5, Tablo 4.6 ve Tablo 4.7’de gösterildi.

Tablo 4.5. Bilateral Ölçümlerin Regresyon Katsayıları.

	B	S.E.	Sig.	95% C.I.	
	B	S.E.	Sig.	Lower	Upper
RMSH	-0,210	0,033	<0,001*	0,759	0,865
RNCH	0,077	0,047	0,102	0,985	1,183
RNCD	-0,056	0,077	0,469	0,813	1,100
RZAH	-0,589	0,115	<0,001*	0,903	1,056
RZAD	-0,589	0,115	<0,001*	0,443	0,695
LMSH	-0,186	0,035	<0,001*	0,775	0,890
LNCH	0,016	0,049	0,740	0,924	1,118
LNCD	-0,328	0,081	<0,001*	0,614	0,845
LZAH	-0,23	0,041	0,571	0,902	1,059
LZAD	-0,617	0,122	<0,001*	0,425	0,686
Constant	24,219	2,031	<0,001*		

Tablo 4.6. Sağ Taraftan Yapılan Ölçümlerin Regresyon Katsayıları.


				95% C.I.	
	B	S.E.	Sig.	Lower	Upper
RNCH	-0,091	0,3	0,002	0,861	0,968
RNCD	-0,126	0,054	0,019	0,793	0,979
RZAH	-0,097	0,027	<0,001*	0,861	0,957
RZAD	-0,847	0,088	<0,001*	0,36	0,509
Constant	11,908	1,168	<0,001*		

Tablo 4.7. Sol Taraftan Alınan Ölçümlerin Regresyon Katsayıları.

				95 % C.I.	
	B	S.E.	Sig.	Lower	Upper
LNCH	-0,093	0,032	0,003	0,856	0,969
LNCD	-0,219	0,06	<0,001*	0,715	0,903
LZAH	-0,096	0,029	<0,001*	0,859	0,96
LZAD	-0,972	0,096	<0,001*	0,314	0,456
Constant	14,199	1,312	<0,001*		


Son olarak makine öğrenmesi algoritmalarına geçildi ve LDA, RFC, SVC, KNN, LR, DT, GNB modelleri tüm ölçümler için çalıştırıldı. Kullanılan verilerin aynı olması için random state değeri “42” alındı.

Çift taraflı alınan ölçümlerden kurulan modellerde en kısa sürede sonuç verenin Doğrusal Diskriminant Analizi olduğu görüldü. GridSearch analizi sonucunda en iyi doğruluk skoruna “n_components=1” hiperparametresiyle ulaşıldı. Konfüzyon matrisi Şekil 4.6’da gösterildi.




Şekil 4.6. Bilateral Ölçümlerin LDA Modeline Ait Konfüzyon Matrisi.

Lojistik Regresyon modelinin en iyi doğruluk oranına “C=0.1, penalty=l1, solver=liblinear” hiperparametresiyle ulaşıldı. Lojistik regresyon konfüzyon matrisi Şekil 4.7’de gösterildi.




Şekil 4.7. Bilateral Ölçümlerin LR Modeline Ait Konfüzyon Matrisi.

Karar Ağacı Sınıflandırma modeli en düşük AUC skoruna (0,825) ve en düşük test skoruna (%76) sahip olan modeldi. GridSearch analizi sonucunda en iyi doğruluk skoruna “max_depth=4, max_features=sqrt, max_leaf_nodes=10, min_samples_split=5” hiperparametresiyle ulaşıldı Konfüzyon matrisi Şekil 4.8’de gösterildi.



Şekil 4.8. Bilateral Ölçümlerin DTC Modeli Konfüzyon Matrisi.


Rastgele Orman Sınıflandırma Modelinin eğitim verilerine ait en yüksek doğruluk oranı (%93) bu modele aitti. GridSearch analizi sonucunda bu skora “min_samples_leaf=2, min_samples_split=7, n_estimators=20” hiperparametresiyle ulaşıldı. Konfüzyon matrisi Şekil 4.9’da gösterildi.



Şekil 4.9. Bilateral Ölçümlerin RFC Modeline Ait Konfüzyon Matrisi.


Test verilerinde en yüksek doğruluk oranına (%83,7) ile genelde en yüksek AUC skoruna (0,92) sahip olan modelin Destek Vektör Makinesi olduğu görüldü. Aynı zamanda Rastgele Orman modeli ile beraber en yüksek duyarlılık oranına (%86) sahipti. GridSearch

analizi sonucuna “C=0.1, gamma=auto, kernel=sigmoid, probability=True” hiperparametreleriyle ulaşıldı. Konfüzyon matrisi Şekil 4.10’da gösterildi.




Şekil 4.10. Bilateral Ölçümlerin SVC Modeline Ait Konfüzyon Matrisi.

K-En Yakın Komşu Sınıflandırma modeline ait konfüzyon matrisine Şekil 4.11’de yer verildi. En iyi doğruluk skorlarına GridSearch analizi sonucunda, “n_neighbors=11” hiperparametre seçimi ile ulaşıldığı görüldü.



Şekil 4.11. Bilateral Ölçümlerin KNN Modeline Ait Konfüzyon Matrisi.

Gaussian Naive Bayes Modeline ait konfüzyon matrisine Şekil 4.12’de yer verildi. Duyarlılığı %80 ile en yüksek model olarak bulundu. En iyi doğruluk skoruna GridSearch analizi sonucunda, “var_smoothing=1e-10” hiperparametre tercihiyle varıldığı görüldü.




Şekil 4.12. Bilateral Ölçümlerin GNB Modeline Ait Konfüzyon Matrisi.

Çift taraflı ölçümlerden kurulan modellerin sonuçlarına Tablo 4.8’de yer verildi. Eğitim ve test verilerine bakıldığında, DTC ve RFC algoritmaları aşırı öğrenmeye uğradı. Tabloya göre; en kısa sürede sonuç veren algoritma LDA, en efektif algoritma ise LR olarak bulundu.

Tablo 4.8. Bilateral Modelin Klasifikasyon Metrikleri.


Model	Doğruluk (Eğitim)	(Doğruluk (Test)	Özgüllük	Duyarlılık	AUC	Süre (Dk:Sn.Salise)
LDA	0,845	0,837	0,804	0,855	0,910	00:00.326973
LR	0,847	0,835	0,914	0,862	0,914	00:05.474820
DTC	0,869	0,762	0,825	0,790	0,825	22:54.105633
RFC	0,935	0,830	0,916	0,864	0,916	23:01.190738
SVC	0,845	0,837	0,923	0,864	0,923	01:08.514051
KNN	0,851	0,812	0,909	0,849	0,909	00:11.044472
GNB	0,821	0,817	0,901	0,824	0,901	00:00.343712

Sağ taraftan alınan ölçümlerde en kısa sürede sonuç veren algoritmanın Doğrusal Diskriminant Analizi olduğu gözlemlendi. En iyi skorlara GridSearch analizi sonucunda, “n_components=1” hiperparametresiyle ulaşıldı ve Şekil 4.13’te gösterildi.




Şekil 4.13. Sağ Tarafa Ait LDA Konfüzyon Matrisi.

Sağ taraf için kurulan Lojistik Regresyon modelimizde en iyi doğruluk skoru için GridSearch analizi sonucunda, “C=0.01, solver=liblinear” hiperparametreleri kullanıldı ve Şekil 4.14’te gösterildi.




Şekil 4.14. Sağ Tarafa Ait LR Konfüzyon Matrisi.

Karar Ağacı Sınıflandırma modelinin en iyi doğruluk skorlarına, GridSearch analizi sonucunda “max_depth=6, max_features=sqrt, max_leaf_nodes=15, min_samples_leaf=4, min_samples_split=15, random_state=42” hiperparametreleri kullanıldı. Konfüzyon matrisine Şekil 4.15’te yer verildi.




Şekil 4.15. Sağ Tarafa Ait DTC Modeli Konfüzyon Matrisi.

Rastgele Orman Sınıflandırma modeli sağ tarafta en iyi eğitim (%86) ve test (%74) skoruna sahipti. Bu skorlara GridSearch analizi sonucunda “min_samples_leaf=6, n_estimators=80, random_state=42” hiperparametreleri ile varıldı. Konfüzyon matrisine Şekil 4.16’da yer verildi.




Şekil 4.16. Sağ Tarafa Ait RFC Modeli Konfüzyon Matrisi.

Destek Vektör Makinesi modelinde en iyi doğruluk skorlarına GridSearch analizi sonucunda, “C=0.3701869055846206, gamma=auto, kernel=sigmoid, probability=True” hiperparametreleriyle ulaşıldı. Konfüzyon matrisine Şekil 4.17’de yer verildi.




Şekil 4.17. Sağ Tarafa Ait SVC Modeli Konfüzyon Matrisi.

K-En Yakın Komşu modelinde en iyi doğruluk skorlarına GridSearch analizi sonucunda, “n_neighbors=13” hiperparametresiyle ulaşıldı. Konfüzyon matrisine Şekil 4.18’de yer verildi.



Şekil 4.18. Sağ Tarafa Ait KNN Modeli Konfüzyon Matrisi.

Gaussian Naive Bayes modelinde en iyi doğruluk skorlarına GridSearch analizi sonucunda, “var_smoothing=1e-10” hiperparametresiyle ulaşıldı. Konfüzyon matrisine Şekil 4.19’da yer verildi.




Şekil 4.19. Sağ Tarafa GNB Modeli Konfüzyon Matrisi.

Sağ tarafa ait ölçümlerden kurulan modellerin sonuçlarına Tablo 4.9’da yer verildi. RFC algoritması aşırı öğrenmeye uğradı. Tabloya göre; en hızlı sonuç veren algoritma LDA, en efektif algoritma ise GNB olarak bulundu.

Tablo 4.9. Sağ Tarafa Ait Modelin Klasifikasyon Metrikleri.


Model	Doğruluk (Eğitim)	(Doğruluk (Test)	Özgüllük	Duyarlılık	AUC	Süre (Dk:Sn.Salise)
LDA	0,720	0,722	0,667	0,770	0,814	00:00.326094
LR	0,727	0,704	0,658	0,742	0,811	00:04.463355
DTC	0,770	0,697	0,642	0,740	0,724	21:30.488937
RFC	0,862	0,742	0,734	0,751	0,778	20:49.446634
SVC	0,733	0,702	0,659	0,738	0,787	01:59.575412
KNN	0,801	0,715	0,715	0,774	0,774	00:10.195104
GNB	0,728	0,716	0,685	0,811	0,811	00:00.343725

Sol taraftan alınan ölçümlerde Doğrusal Diskriminant Analizi modeli için GridSearch analizi sonucunda “n_components=1” hiperparametresi kullanıldı ve bu model en kısa sürede sonuç verdi. Konfüzyon matrisi Şekil 4.20’de gösterildi.




Şekil 4.20. Sol Tarafa Ait LDA Konfüzyon Matrisi.

Lojistik Regresyon modelinde en iyi doğruluk skorlarına “C=0.001, solver=liblinear” hiperparametreleri ile ulaşıldı. Sol tarafta Test verilerinde en iyi doğruluk skoruna GridSearch analizi sonucunda (%75) Lojistik Regresyon modelinde ulaşıldı. Konfüzyon matrisine Şekil 4.21’de yer verildi.




Şekil 4.21. Sol Tarafa Ait LR Modeli Konfüzyon Matrisi.

Karar Ağacı Dınıflandırma modelinde en iyi skorlar için GridSearch analizi sonucunda, “max_depth=13, max_features='sqrt', max_leaf_nodes=15, min_samples_leaf=4, min_samples_split=5, random_state=42, splitter=random” hiperparametreleri kullanıldı. Konfüzyon matrisine Şekil 4.22’de yer verildi.




Şekil 4.22. Sol Tarafa Ait DTC Modeli Konfüzyon Matrisi.

Rastgele Orman Sınıflandırma modeline ait en iyi skorlara ulaşmak için GridSearch analizi sonucunda, “min_samples_leaf=7, n_estimators=20, random_state=42” parametreleri kullanıldı. Modeller arasında duyarlılığı en yüksek olan model (%75) Rastgele Orman Sınıflandırma modeliydi. Konfüzyon matrisine Şekil 4.23’te yer verildi.




Şekil 4.23. Sol Tarafa Ait RFC Modeli Konfüzyon Matrisi.

Destek Vektör Makinesi modelinde en iyi doğruluk skorlarına GridSearch analizi sonucunda, “C=0.19240241827602392, gamma=auto, kernel=sigmoid, probability=True” hiperparametreleri kullanıldı. Konfüzyon matrisine Şekil 4.24’te yer verildi.




Şekil 4.24. Sol Tarafa Ait SVC Modeli Konfüzyon Matrisi.

K-En Yakın Komşu modelinde en iyi doğruluk skoruna GridSearch analizi sonucunda, “n_neighbors=11” hiperparametresi ile ulaşıldı. Konfüzyon matrisine Şekil 4.25’te yer verildi.



Şekil 4.25. Sol Tarafa Ait KNN Modeli Konfüzyon Matrisi.

Gaussian Naive Bayes modelinde en iyi doğruluk skoruna GridSearch analizi sonucunda, “var_smoothing=1e-10” hiperparametresi ile ulaşıldı. Konfüzyon matrisine Şekil 4.26’da yer verildi.



Şekil 4.26. Sol Tarafa Ait GNB Modeli Konfüzyon Matrisi.

Sol tarafa ait ölçümlerden kurulan modellerin sonuçlarına Tablo 4.10’da yer verildi. Tabloya göre KNN algoritması aşırı öğrenmeye gitti. En hızlı sonuç veren algoritma LDA, en efektif algoritma ise GNB olarak bulundu.

Tablo 4.10. Sol Tarafa Ait Modelin Klasifikasyon Metrikleri.

Model	Doğruluk (Eğitim)	Doğruluk (Test)	Özgüllük	Duyarlılık	AUC	Süre (Dk:Sn.Salise)
LDA	0,747	0,748	0,755	0,745	0,823	00:00.271125
LR	0,759	0,753	0,768	0,741	0,810	00:03.565503
DTC	0,750	0,700	0,727	0,678	0,776	17:27.629350
RFC	0,801	0,735	0,717	0,751	0,816	16:37.776706
SVC	0,729	0,732	0,728	0,736	0,812	02:34.865965
KNN	0,865	0,712	0,716	0,709	0,781	00:09.923760
GNB	0,757	0,750	0,772	0,732	0,813	00:00.300656

Bu çalışmada cinsiyet tahmini için yedi farklı makine öğrenme algoritması kullanıldı. Algoritmalara ait tablolar incelendiğinde her birinin farklı sonuçlar verdiği gözlemlendi. Yapılan değerlendirmeler ışığında her üç modelde de en kısa sürede sonuç veren algoritma; Doğrusal Diskriminant Analiziydi.

Bilateral (%93) ve sağ tarafa ait (%86) ölçümlerde, eğitim verilerine ait en yüksek doğruluk skoru Rastgele Orman Sınıflandırma algoritmasına aitti. Sol tarafa ait ölçümlerde ise eğitim verilerine ait en yüksek doğruluk skoru (%86) K-En Yakın Komşu algoritmasında görüldü.

Test verilerine ait doğruluk skorlarına bakıldığında; bilateral ölçümlerde %83 ile Destek Vektör Makinesi, sağ tarafta %74 ile Rastgele Orman Sınıflandırma modeli, sol tarafta %75 ile Lojistik Regresyon algoritması karşımıza çıktı.

5. TARTIŞMA

Kimliğin doğru bir şekilde tespit edilmesi; cinsiyet, yaş, ırk ve boy tahmininde referans teşkil ettiği için anatomi, arkeoloji, odontoloji, antropoloji, osteoloji bilimlerinde; tecavüz ve kitlesel afet durumlarında şüpheli sayısını yarıya düşürdüğü için adli tıpta hayati öneme sahiptir (13, 40, 41, 83, 84).

Cinsiyetlerin spesifik özellikleri ergenlik dönemini takiben ortaya çıkmakta ve bu dönemde belirginleşmektedir. Antropolojik açıdan en güvenilir cinsiyet tahmin yöntemlerinin yetişkin bireyler için oluşturulduğu çalışmalarda belirtilmiştir (85).

Geleneksel morfometri yöntemi; noktalar arasındaki mesafe, açılar ve oranlar ile elde edilen uzunluklar, derinlik, genişlik gibi ölçülere dayanmaktadır (86). Bahsi geçen geleneksel yöntemler, genetik ve moleküler tekniklerin gelişmesi ve doğruluk oranının yüksekliğine rağmen üst düzeyde beceri, yüksek maliyet ve uzmanlık bilgisi gerektirdiğinden günümüzde hâlen önemini korumaktadır (87).

Ajanoviç ve ark. Bosna halkına ait 209 bireyin kafatasındaki sert damaktan, geometrik morfometrik ölçümlerle cinsiyet tahmininde bulunmuşlardır. Yaptıkları çalışmanın sonucunda erkeklerde %68,34 ve kadınlarda %64,29 doğruluk skoruna ulaşmışlardır (94).

Bharath ve ark. Andhra Pradeş popülasyonundan 100 bireyden ortodontik tedavi öncesi alçı ile rugae palatina desenlerini almışlardır. Rugae palatina desenleri ile cinsel dimorfizm arasındaki ilişkiyi anlamlandırmak için Diskriminant Fonksiyon Analizi kullanılmışlardır. Rugae palatina uzunluğu ve şekli ile cinsiyet belirleme arasındaki ilişkinin bu popülasyondaki doğruluk oranı %78 olarak belirtilmiştir (95).

Pinskerova ve ark. distal femur morfolojisindeki farklılıkları araştırmışlardır. Bu amaçla; 200 normal femurda bulunan anatomik noktalara ait manyetik rezonans görüntülerinden antropometrik veriler elde edilmiştir. Ölçülen tüm değişkenlerde kadın distal femur boyutları istatistiksel olarak önemli ölçüde daha küçük ($p<0,05$) bulmuşlardır (96).

Marinescu ve ark. Romanya popülasyonu örneğinden 200 bireye ait kafatası üzerinde çalışmışlardır. Sağlam kafatası ölçümlerindeki doğruluk oranı %88, calvaria ölçümlerindeki doğruluk oranı %81 ve yüz ölçümlerindeki doğruluk oranı %83,5 olarak bulmuşlardır (97).

Manoel ve ark. Brezilya popülasyonuna ait 215 bireyin kafatasından foramen magnum'un morfometrik ölçümleriyle cinsiyetlerini tahmin etmişlerdir. Foramen magnum'un yüksekliğini erkeklerde istatistiksel olarak kadınlardan daha yüksek, ancak uzunluk olarak daha düşük bulmuşlardır (98).

Gillespie ve ark. yaptıkları çalışmada femurun anatomik yapılarındaki ölçümlerden cinsel farklılıkları araştırmışlardır. Hamann-Todd koleksiyonundaki 1207 adet kadavranın femurundan morfometrik ölçümler yapılmış, erkeklerde femurun ortalama en-boy oranının, kadın femurunun ortalama en-boy oranından istatistiksel olarak anlamlı ($p<0,001$) bulmuşlardır (99).

Bireyin bütün kemikleri eksiksiz olduğunda %95-100 oranında doğruluk elde edilebilmekteyken, pelvis ve cranium ile %98, yalnızca pelvis ile %95 oranında doğruluğa ulaşılabilmektedir (87, 88, 89).

Decker ve ark. 3B BT görüntülerinden yetişkin bireylerin pelvisini ölçerek cinsiyeti belirlemeye çalışmışlardır. İstatistiksel analizlere dayanarak cinsiyet tahmini için dört değişkenli bir diskriminant fonksiyonu geliştirmişler, genel olarak, bu yöntemin çapraz doğrulanmış doğruluğu %100, gözlemciler arası hata ise ortalama %2,2 olarak bulunmuştur (10).

Gomez ve ark. Meksika Ulusal Özerk Üniversitesine ait iskelet serisinden toplam 146 yetişkin bireyin pelvis kemiğini değerlendirmişlerdir. Diskriminant Fonksiyon Analizi uygulanarak taraflar ve cinsiyet farklılıkları incelemişler, koksal ve sakral fonksiyonlarda sırasıyla %99 ve %87 doğruluk oranı elde etmişlerdir (85).

BT yöntemi; geleneksel yöntemleri sistematikleştirerek daha hassas ölçüm yapma imkânı sağlamakta, kemik yapıya zarar vermemekte ve gelişmiş bir veri kaynağı sunmaktadır. (9, 10, 90). Buna istinaden cinsiyet tayini için popüler bir seçenektir. Kafatasının morfolojik oluşumlarının BT görüntülerinden elde edilen veriler, bilimsel çalışmalarda cinsiyet tayini için sıklıkla kullanılmaktadır (91, 92).

Çekdemir ve ark. 616 adet kraniyal BT görüntüsünden yaptıkları morfometrik ölçümler ile cinsiyet tahmininde bulunmuşlardır. Maksimum kraniyal uzunluk (%87,4), bizigomatik genişlik (%89,2) ve bimastoit çap (%84,8) değişkenlerinin cinsiyeti tahmin etmede başarılı olduğunu göstermişlerdir (91).

Dereli ve ark. 85 adet bireyin BT görüntüsünden 3B modelleme teknikleriyle kafatasının cinsiyete bağlı özelliklerini incelemişlerdir. Edinilen veriler üç kör gözlemci tarafından İnsan İskelet Kalıntılarından Veri Toplama Standartları'na göre 1-5 puanlık bir ölçek ile puanlandırılmıştır. Doğru cinsiyet tahmin oranları sırasıyla %91,8, %92,9 ve %92,9 olmuştur. Üç gözlemci arasındaki cinsiyet tahminindeki tutarlılık %83,5 olarak bulunmuşlardır (92).

Cohen ve ark. çalışmalarında 201 adet BT görüntüsünden maksiller, sfenoit ve frontal sinüslerin hacimlerini karşılaştırmalı olarak incelemişlerdir. Erkeklerde tüm sinüslerin hacim ortalamalarının kadınlardan daha yüksek olduğunu ($p<0,001$) kaydetmişlerdir (93).

Teke ve ark. yaptıkları prospektif çalışmada 127 yetişkin bireyin BT görüntülerinden maksiller sinüslerin genişliği, uzunluğu ve yüksekliğini ölçerek cinsiyeti belirlemeye çalışmışlardır. Diskriminant Fonksiyon Analizi sonucunda kadınlarda %69,4 ve erkeklerde %69,2 doğruluğa ulaşmışlardır (100).

Hamd ve ark. KIBT görüntülerinden maksiller sinüs hacmini ölçerek makine öğrenmesi algoritmalarıyla cinsiyet tahmininde bulunmuşlardır. Çalışma sonunda sağ ve sol sinüsler için %97 ila %98 arasında değişen doğruluk skorlarına ulaşmışlardır (101).

Bangi ve ark. 100 adet bireyin BT görüntüsünden maksiller sinüslerin üç boyutlu ölçümlerini kullanarak cinsiyet tespit etmişlerdir. Genel doğruluk oranının %88, erkeklerde %84, kadınlarda %92 olduğunu görmüşlerdir (102).

Tiwari ve ark. 90 hastanın BT görüntülerinden maksiller sinüsleri ölçerek cinsiyet tahmini çalışması yapmışlardır. Ortalama AP çapı erkeklerde kadınlardan daha büyük olarak ve ortalama fark yaklaşık 1,8 mm olarak kaydedilmiştir. ML çapı her iki tarafta da erkek ve kadınlarda istatistiksel olarak anlamlı bulunmamıştır ($p>0,05$). İki boyutlu görüntülerde erkek ve kadınlarda SI çapında ortalama anlamlı bir fark bulunmuştur. Maksiller sinüs hacmi cinsiyetler arasında $p<0,001$ ile anlamlı farklılık görmüşlerdir (103).

Prabhat ve ark. çalışmalarında BT görüntülerinden maksiller sinüslerin hacmini ve boyutunu ölçerek cinsiyeti tahmin etmişlerdir. Cinsiyetler arasında sol maksiller sinüslerin sağ SI boyutunda, sol SI boyutunda ve sol AP, maksiller sinüsün sağ AP boyutunda istatistiksel olarak anlamlı bir ($p<0,05$) fark görmüşlerdir. Yöntemlerinin genel doğruluk oranı %83,3, erkeklerde %80, kadınlarda ise %86,7 olarak kaydetmişlerdir (7).

Bizde çalışmamızda Tiwari ve ark., Prabhat ve ark. ile uyumlu olarak maksiller sinüsün AP ölçümlerini; solda erkeklerde, sağda kadınlarda daha yüksek bulduk. Maksiller sinüsün SI ölçümlerinde; sol tarafta erkeklerde, sağ tarafta ise kadınlarda anlamlı bir fark gördük. ($p<0,001$).

Ekizoğlu ve ark. 140 bireye ait BT görüntülerinden maksiller sinüslerin morfometrik özellikleriyle cinsiyet tespiti yapmışlardır. Kullandıkları tüm değişkenlerin erkeklerde kadınlardan daha yüksek olduğunu görmüşlerdir. Kadınlarda doğru tahmin etme oranını %80, erkeklerde ise %74,3 olarak bulmuşlardır (104).

Biz de çalışmamızda Ekizoğlu ve ark. uyumlu olarak; BT görüntülerinden elde ettiğimiz maksiler sinüslerin morfolometrik ölçümlerinde LMSD, LMSH değişkenlerini erkeklerde daha yüksek bulduk.

Akyıldız yaptığı retrospektif bir çalışmada; 250 kadın ve 250 erkek olgunun kraniyal BT görüntüleri kullanarak foramen magnum ve kafa antropometrik çap ölçümleriyle cinsiyet tahmin etmiştir. Lojistik Regresyon sonucu kadınların %81,2'si ve erkeklerin %77,6'sı doğru tahmin edilirken Diskriminant Fonksiyon Analizi sonucu ise kadınların %80,8'isini ve erkeklerin de %76'sını doğru olarak tahmin etmişlerdir (5).

Toy ve ark. 300 adet kafatası iskeletinin BT görüntülerinden edinilen değişkenlerle makine öğrenmesi algoritmalarını kullanarak cinsiyet tahmininde bulunmuşlardır. Kafatası iskeletinin BT görüntülerinden elde edilen parametrelere uygulanacak Lojistik Regresyon algoritmasının cinsiyeti en yüksek doğrulukla (%87,76) tahmin edeceği sonucuna varmışlardır (105).

Biz de Akyıldız ve ark, Toy ve arkadaşlarıyla uyumlu olarak; bilateral ölçümlerden aldığımız eğitim verilerinde %84, test verilerinde %83 ile en iyi doğruluk skoruna Lojistik Regresyon modeliyle ulaştık.

KIBT yöntemi maksillofasiyal alanda paranazal sinüsler, maksilla, mandibula, temporal kemik, paranazal sinüsler gibi sert dokulara ait anatomi, varyasyon ve patolojilerin incelenmesine olanak sağlar. Bu yöntemin, BT'ye nazaran radyasyon dozunun az olması, MRG ye nazaran görüntü elde etme ve yorumlamasının kolay olması gibi avantajları mevcuttur (54). Günümüzde yaygın kullanılan KIBT görüntülerinin adli tıp alanında kullanıldığı, yaş ve cinsiyet tayininin yapıldığı pek çok çalışma mevcuttur (55, 56, 57.) Biz de buradan hareketle çalışmamızda KIBT yöntemini kullandık.

Demiralp ve ark. çalışmalarında 32 adet antik kafatasından KIBT görüntüleri ile paranazal sinüs boyutlarının ve hacmini ölçerek cinsiyet ve yaş tahmininde bulunmuşlardır. Sfenoidal sinüsün ön-arka duvarına olan mesafe erkeklerde daha fazla ($p>0,05$), frontal sinüsün genişliği ve hacminin 60 yaş üstü yaşla birlikte istatistiksel olarak arttığını ($p>0,05$) gözlemlemişlerdir (55).

Wanzeler ve ark. çalışmalarında KIBT yöntemi ile maksiller, frontal ve sfenoidal sinüsleri ve foramen magnum ölçümleri ile cinsiyet korelasyonlarını değerlendirmişlerdir. Kadın bireylerin maksiller, frontal ve sfenoidal sinüs hacimleri erkek bireylerden daha küçük olarak bulmuşlardır ($p<0,001$). Çalışma sonucunda bireyin cinsiyetini doğru olarak tayin edilme oranını erkeklerde %96,2, kadınlarda %92,7 olarak görmüşlerdir. Elde edilen

değerlerin foramen magnum ölçümleri ile ilişkilendirilmesi durumunda cinsiyet tespit oranını %100'e yakın bulmuşlardır (57).

Meyvacı ve ark. 197 yetişkin bireyin KIBT görüntülerinden mandibular morfometrinin açısal parametreleriyle cinsiyet değerlendirmesinde bulunmuşlardır. Çalışma sonucunda; cinsiyet tahmininin %71,5 genel doğrulukla yapılabileceğini göstermişlerdir (106).

Günümüzde cinsiyet tahmini gerçekleştirmek için muhtelif yöntemler mevcuttur. Yapay zekânın bir dalı olan makine öğrenme algoritmaları da bu yöntemlerden biridir. Literatür tarandığında makine öğrenme algoritmaları kullanılarak bulguların gruplandırıldığı, hastalıkların tahmin edildiği ve cinsiyetin tayin edildiği faydalı pek çok çalışmaya rastlanılmaktadır (11, 70, 52, 14, 12, 5). Yapay zekânın sağlık sektörüne uyarlanması sonucunda daha kesin sonuçlara, daha düşük maliyetle ve daha kısa sürede ulaşıldığı çalışmalarda belirtilmiştir (65, 66).

Kaya ve ark. 2019 yılında yaptıkları yayında hastalıkların erken tanısında kullanılan derin öğrenme yöntemleri incelenmişlerdir. Derin öğrenme mimarilerinin temelindeki matematiksel modellemelerin ne kadar iyi anlaşılırsa gelecekte de derin öğrenme yöntemlerinin de o kadar başarılı olacağı kanaatine varmışlardır (12).

Stoltzfus doktora tezinde Lojistik Regresyonun tıbbi araştırmalardaki önemini ve gerekliliğini araştırmıştır. Klinik olarak anlamlı ve nesnel bir hipotez geliştirmek, uygun bir çalışma tasarımı ve istatistiksel analiz yapmanın çalışma için öneminden bahsetmiştir. Bu nedenle iyi tasarlanmış bir çalışmada Lojistik Regresyon analizinin, kanıta dayalı acil tıbbı en anlamlı katkıyı sağlayacağı sonucuna varmıştır (80).

Kartal ve ark. Diskriminant Analizini ve Yapay Sinir Ağlarını kullanarak yaptıkları çalışmada, foramen magna ait morfometrik ölçümler gerçekleştirmişler ve cinsiyet tahmininde bulunmuşlardır. Çalışmada 720 bireyin BT görüntülerini kullanarak Diskriminant Analizi ile %86,7 doğruluk skoruna ulaşmışlardır. Yapay Sinir Ağları yöntemi sayesinde ise cinsiyetin %88,2 oranında doğru tahmin edildiğini belirtmişlerdir (107).

Neelaveni ve ark. Alzheimer tanılı hastaları tahmin etmek için Destek Vektör Makinesi ve Karar Ağacı algoritmalarını kullanmıştır. Çalışma sonucunda, Alzheimer hastalığını doğru tahmin etme skoru Destek Vektör Makinesinde modelinde %85, Karar Ağacı modelinde ise %83 olarak bulunmuşlardır (108).

Nurzynska ve ark. 166 bireye ait vertebra gövdesinin BT görüntülerinden elde edilen veri setiyle yaş ve cinsiyet tahmininde bulunmuşlardır. Makine öğrenimi ile cinsiyetin sınıflandırılmasında doğruluk skoru %69 olarak bulunmuş, derin evrişimli ağların

uygulanması ile %59 oranında, makine öğrenmesinden daha düşük bir doğruluğa ulaşmışlardır (109).

Pisharody ve ark. çalışmalarında makine öğrenmesi algoritmaları aracılığıyla cinsiyet tahmininde bulunmuşlardır. Yapılan çalışmada 465 bireye ait parmak izi incelenmiş ve cinsiyet tahmininde en başarılı algoritmanın %94,62 doğruluk oranıyla Rastgele Orman Sınıflandırma modeli olduğunu belirtmişlerdir (110).

Sevli bir çalışmasında göğüs kanseri teşhisinde farklı makine öğrenmesi tekniklerinin performans karşılaştırmasını yapmıştır. Her biri 30 adet özellik içeren ve 569 örnekten oluşan Wisconsin Üniversitesine ait göğüs kanseri veri setini, beş farklı makine öğrenmesi tekniği ile sınıflandırmıştır. Destek Vektör Makinesi, Gaussian Naive Bayes, Rastgele Orman Sınıflandırma, K-En Yakın Komşu ve Lojistik Regresyon metotları kullanılmış olup Lojistik Regresyon modelinin %98.24 doğruluk ile en başarılı yöntem olduğu ortaya koymuştur (13).

Ahmed ve ark. çalışmalarında daha iyi sağlık hizmetleri ve hassas tıp için makine öğrenimi platformu geliştirmesine sahip yapay zekâyı incelemişlerdir. Yapay zekâ ve makine öğreniminin tıp alanında başarı ortaya çıkararak sağlık hizmetlerinin kalitesini ve gelişimini iyileştirme potansiyeline sahip olduğu kanaatine varmışlardır (65).

Leavitt ve ark. 2023 yılında yaptıkları çalışmada Rastgele Orman Sınıflandırma, Lojistik Regresyon ve Destek Vektör Makinesi algoritmalarını kullanarak ortodontik çekim modellerini tahmin etmişlerdir. Veri setini rastgele olarak eğitim (%70) ve test setlerine (%30) bölmüşlerdir. Genel doğruluk skorları Rastgele Orman Sınıflandırma modeli %54,55 ile en yüksek yüzdeyi verirken, bunu %52,73 ile Destek Vektör Makinesi ve %49,09 ile Lojistik Regresyon algoritmaları takip etmiştir (111).

Veranyurt ve ark. hastalık sınıflandırması yapmak için makine öğrenme algoritmalarını kullanmışlardır. Çalışma sonucunda, Rastgele Orman Sınıflandırma ve K-En Yakın Komşu algoritmaları sınıflandırma başarısının %92,30 ve AdaBoost algoritması ile gerçekleştirilen sınıflandırma başarısının ise %90,59 olduğu tespit etmişlerdir (11).

Etli ve ark. 480 bireye ait sakrum ve koksa BT görüntülerinden, 21 farklı değişken ölçümüyle cinsiyet tahmini yapmışlardır. Çalışmada Univaryant Diskriminant Analizi, Doğrusal Diskriminant Fonksiyon Analizi, Adım Adım Diskriminant Fonksiyon Analizi ve Çok Katmanlı Algılayıcı Sinir Ağları modelleri kurulmuştur. Univaryant Diskriminant Analizinin doğruluk oranı %67,1, Doğrusal Diskriminant Fonksiyon Analizinin doğruluk oranı %82,5, Adım Adım Diskriminant Fonksiyon Analizinin %78,8 ve Çok Katmanlı Algılayıcı Sinir Ağlarının doğruluk oranı %86,3 olarak bulunmuştur (112).

Curate ve ark. Portekiz popülasyonundan 200 bireye ait femurdan çeşitli ölçümlerle, makine öğrenmesi algoritmalarıyla cinsiyet tahmininde bulunmuşlardır. Lojistik Regresyon, Doğrusal Diskriminant Analizi, Destek Vektör Makinesi ve Azaltılmış Budama Hatası Ağaçları modellerini kullanmışlardır. Araştırmalarının sonucunda çok değişkenli modeller vasıtasıyla doğruluk oranının %84-92,5 arasında sınıflandırılabileceğini belirtmişlerdir (113).

Santosh ve ark. toplam 1142 hastanın ortopantomogram görüntüsünden makine öğrenmesi teknikleriyle cinsiyet tahmininde bulunmuşlardır. Yaş tahmini için Multiclass Destek Vektör Makinesi sınıflandırıcı algoritması ve cinsiyet tahmini için LIBSVC sınıflandırıcısını kullanarak %96 doğruluk elde etmişlerdir (16).

Ataş 2022’de yaptığı çalışmada; panoramik radyografi görüntülerinden derin öğrenme yöntemiyle cinsiyet tahmin etmiştir. Çalışmada 24.000 dental panoramik görüntüden oluşan bir veri seti üzerinde çalışmış, mandibular anatomik yapılar üzerinden ölçümlerle, derin transfer öğrenme modelleri VGG16, ResNet50 ve EfficientNetB6 kullanılarak karşılaştırmalar yapmıştır. Karşılaştırmalı analizinin bulgularına göre cinsiyet sınıflandırmasında %97,25’lik bir başarı oranına ulaşmışlardır (114).

Ortiz ve ark. panoramik radyografi görüntülerinden alınan alt mandibulaya ait 13 doğrusal ve açısal ölçüm ile makine öğrenmesi vasıtasıyla cinsiyet tahmininde bulunmuşlardır. Diskriminant analizi testinin doğruluğunu %70 bulurken, Makine öğrenimi teknikleri ile yaptıkları tahminlerindeki doğruluk %95’e yükselmiştir (115).

Amin ve ark. genç yetişkin Ürdün popülasyonu üzerinde yaptıkları cinsiyet tahmini çalışmasında 146 dijital sefalometrik hasta görüntüsünden 19 tane kroniyofasiyal anatomik noktayı ölçmüşlerdir. Corpus mandibulae uzunluğu haricinde, erkek bireylerin diğer tüm parametrelerinin ortalama değerlerinin, kadınlara göre istatistiksel olarak anlamlı derecede daha büyük ($p<0.001$) olduğunu bulmuşlardır. Diskriminant Fonksiyon Analiziyle %87,7 doğruluk oranına ulaşmışlardır (116).

Vila-Blanco ve ark. 3400 adet bireyin panoramik görüntüsünden mandibulanın anatomik yapıları üzerinden, DASNET, DSANET, VGG16 derin öğrenme algortimalarını kurmuşlardır. Bu yaklaşımın özellikle on altı yaşının üzerindeki yetişkin bireylerde daha doğru oranda sonuç verdiğini gözlemlemişlerdir. Çalışma sonucunda %83’ün üzerinde doğru tahminde bulunmuşlardır (117).

Öner ve ark. yaptıkları çalışmada, patellanın çok dedektörlü BT görüntülerinden bir makine öğrenme algoritması olan Karar Ağacı Sınıflandırma yöntemi ile cinsiyetin belirlenip belirlenemeyeceğini analiz etmeyi amaçlamışlardır. Ortogonal düzlemde ölçülen patellanın anteroposterior, kraniyokaudal, mediolateral ve hacimlerini hesaplamışlardır. Patella

morfometrisine dayanan Karar Ağacı Sınıflandırma analizinin cinsiyet tahmini için yeterli ve yüksek doğruluklu bir yaklaşım sağladığını belirtmişlerdir (118).

Diac ve ark. Romanya popülasyonunda yaptıkları çalışmada lomber 1-5 vertebraların morfometrisinden makine öğrenmesi yöntemiyle cinsiyeti tahmin etmişlerdir. Doğruluk ve Roc-AUC oranları ile cinsiyet belirlemede Makine öğrenmesi algortimalarının (%96,3) Diskriminant Fonksiyon Analizine göre (%86,8) daha yüksek doğruluğa ulaştığını belirtmişlerdir (119).

Nogueira ve ark. 78 bireyin sol radius kemiğinin proksimal kısmında, distal kısmında ve kemiğin tamamında on altı ölçüm yapmışlardır. Doğrusal Diskriminat Analizi, Esnek Diskriminant Analizi, Düzenlendirilmiş Diskriminant Analizi, Cezalandırılmış Lojistik Regresyon, Rastgele Orman Sınıflandırma ve Destek Vektör Makinesi algoritmalarını kullanarak %94'ün üzerinde bir doğruluk oranına ulaşmışlardır (120).

Biz de makine öğrenme algoritmalarıyla cinsiyet tahmininde bulunmayı hedefledik, bu doğrultuda 344 erkek, 408 kadın toplamda 752 hastaya ait BT görüntülerinden alınan morfometrik ölçümler ile veri seti hazırladık. Veri setimizi Rastgele Orman Sınıflandırma, Karar Ağacı, K-En Yakın Komşu, Gaussian Naive Bayes, Doğrusal Diskriminant Analizi, Destek Vektör Makinesi algoritmaları ile çalıştırdık.

Yaptığımız çalışmaya baktığımızda; bilateral ölçümlerde; eğitim verilerinde %84, test verilerinde %83, AUC değerinde ise %91 skoru ile en iyi algoritmayı LR olarak bulduk. Sağ tarafa ait ölçümlerde; eğitim verilerinde %72, test verilerinde %71 ve AUC %81 skoru ile en efektif algortimayı GNB olarak bulduk. Sol tarafa ait ölçümlerde eğitim verilerinde %75, test verilerinde % 75, AUC %81 oranı ile en başarılı algoritmayı GNB olarak bulduk.

Eğitim ve test verilerine bakarak, overfitting durumunu değerlendirdiğimizde bilateral ölçümlerde DTC ve RFC, sağ tarafta RFC, sol tarafta KNN aşırı öğrenmeye uğradı.

6. SONUÇ VE ÖNERİLER

Retrospektif olan bu çalışmamızda; gelişimsel-kemiksel bozukluklar yahut iskelet maloklüzyonu olmayan, ilgili anatomik bölgelerde herhangi bir anomali ya da deformitesi bulunmayan, herhangi bir ortodontik veya ortognatik tedavi görmeyen, 20-65 yaş aralığında olan, 752 yetişkin bireyin BT görüntülerini ölçerek cinsiyet tahmin etmeyi hedefledik.

Maksiller sinüs, nazal kavite ve zigomatik arkta bulunan değişkenlerimizden elde ettiğimiz veriler doğrultusunda;

1. LMSD, LMSH, LNCD, LZAD, RNCH, RNCD, RZAH, RZAD değişkenlerinin erkeklerde kadınlardan istatistiksel olarak anlamlı yükseklikte olduğunu,
2. LMSD VE RMSD değişkenleri arasındaki korelasyonun (0,797) diğer değişkenlerden daha yüksek olduğunu,
3. Cinsiyet farketmeksizin maksiller sinüs yüksekliğinin ve zigomatik ark yüksekliğinin sağ tarafta, nazal kavite yüksekliğinin ise sol tarafta daha yüksek olduğunu,
4. GNB ve LR makine öğrenmesi algoritmalarının cinsiyeti tahmin etme becerisinin kullandığımız diğer modellere nazaran daha yüksek olduğunu,
5. Anatomik ölçümleri alınacak birey sayısının artmasının çalışmanın nihayetini pozitif yönde değiştireceğini düşünmekteyiz.

7. KAYNAKLAR

(Bu tez çalışmasında Vancouver atıf sistemi kullanılmıştır.)

1. Gulhan, O., Harrison, K., & Kiris, A. (2015). A new computer-tomography-based method of sex estimation: Development of Turkish population-specific standards. *Forensic science international*, 255, 2-8.
2. Saukko P., Knight Bernard. The Establishment of Identity of Human Remains. In: Knight's Forensic Pathology. 2016. p. 95,132.
3. Tersigni-Tarrant MA, Langley NR. Forensic Anthropology and the Crime Scene. In: Tersigni-Tarrant MA, Langley NR, editors. *Forensic Anthropology A Comprehensive Introduction*. 2nd ed. 2017. p. 7–22.
4. Blau S. How traumatic: a review of the role of the forensic anthropologist in the examination and interpretation of skeletal trauma. *Australian Journal of Forensic Sciences*. 2017 May 4; 49(3):261–80.
5. Akyıldız, A. (2023). Gender prediction with 3D cranial CT images and foramen magnum and head anthropometric diameter measurements: A retrospective study.
6. Best, KC, Garvin, HM, & Cabo, LL (2018). Examining the Relationship Between Human Cranial and Pelvic Sexual Dimorphism. *Journal of Forensic Sciences*, 63 (4), 990-1000. doi: 10.1111/1556-4029.13669.
7. Prabhat, M., Rai, S., Kaur, M., Prabhat, K., Bhatnagar, P., & Panjwani, S. (2016). Computed tomography based forensic gender determination by measuring the size and volume of the maxillary sinuses. *Journal of forensic dental sciences*, 8(1), 40.
8. Torimitsu, S., Makino, Y., Saitoh, H., Sakuma, A., Ishii, N., Yajima, D. & Iwase, H. (2015). Morphometric analysis of sex differences in contemporary Japanese pelvises using multidetector computed tomography. *Forensic science international*, 257, 530-e1.
9. Grabherr S., Cooper C., Ulrich-Bochsler S., Uldin T., Ross S., Oesterhelweg L., Thali M. J. Estimation of sex and age of virtual skeletons –a feasibility study. *European radiology*.2009; 19(2), 419-429.
10. Decker SJ, Davy-Jow SL., Ford JM., Hilbelink D. R. Virtual determination of sex: metric and nonmetric traits of the adult pelvis from 3D computed tomography models. *Journal of forensic sciences*. 2011; 56(5), 1107-1114.
11. Veranyurt Ü., Deveci A., Esen MF., Veranyurt O., et al. Makine öğrenmesi teknikleriyle hastalık sınıflandırması: random forest, k-nearest neighbour ve adaboost algoritmaları uygulaması. *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi*, 2020; 6(2), 275-286.
12. Kaya U., Yılmaz A., Dikmen Y. Sağlık alanında kullanılan derin öğrenme yöntemleri. *Avrupa Bilim ve Teknoloji Dergisi*, 2019; (16), 792-808.
13. Seveli, O. (2019). Göğüs kanseri teşhisinde farklı makine öğrenmesi tekniklerinin performans karşılaştırması. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 176-185.
14. Ucuzal, H. (2020). Yapay Zekâya Dayalı Anlamsal Video İşleme Yöntemlerinin Tıpta Kullanılabilirliğinin Araştırılması. Master's Thesis, İnönü Üniversitesi Sağlık Bilimleri Enstitüsü.
15. Özkara Sönmez, E. Dijital panoramik radyografilerde morfometrik ölçümlerin çocuklarda yaş ve cinsiyet tayininde kullanılabilirliğinin retrospektif olarak araştırılması.
16. Santosh, K. C., Pradeep, N., Goel, V., Ranjan, R., Pandey, E., Shukla, P. K., & Nuagah, S. J. (2022). Machine learning techniques for human age and gender identification based on teeth X-ray images. *Journal of Healthcare Engineering*, 2022.
17. Hammond, J. D. (2023). Essentials of Embryology for the Musculoskeletal System. In *Orthopaedics for the Newborn and Young Child: A Practical Clinical Guide* (pp. 3-17). Cham: Springer International Publishing.
18. Breeland, G., Sinkler, M. A., & Menezes, R. G. (2022). Embryology, bone ossification. In StatPearls [Internet]. StatPearls Publishing.
19. Sadler TW. Langman's medical embryology. 12th ed. Philadelphia: Lippincott Williams &Wilkins; 2012.
20. Akkoç MF., Aşır F. Baş-boyun bölgesi embriyolojisi. Yılmaz M, editör. *Maksillofasiyal Cerrahi*. 1. Baskı. Ankara: Türkiye Klinikleri; 2022. p. 1-3.

21. Fix JD. Brueckner JK. High-Yield Neuroanatomy. 5th ed.
22. Moore KL. Dalley AF., Agur AMR. Clinically oriented anatomy. 8th ed. Wolters Kluwer; 2017.
23. Steding G., Jian Y. The origin and early development of the nasal septum in human embryos. *Annals of Anatomy-Anatomischer Anzeiger* 2010; 192: 82-85.
24. Junqueira, L. C., Carneiro, J., & Kelley, R. O. (1993). Basic Histology, Çeviri (Translation) Ed: AYTEKİN Y: Temel Histoloji. 7. Baskı, Barış Kitabevi, İstanbul, 346-356.
25. Selçuki M. ve Özdemir S. Kalvaryum'un Embriyolojik Gelişimi. *Türk Nöroşir Dergisi*, (2017).
26. Shellshear J. Topographic and clinical anatomy of the head and neck. 1st ed. Wiley- Blackwell; 2015.
27. Babacan S. Yeniden Yüzlendirmeye Yönelik Mandibulası Bulunmayan Kafataslarında Yaş, Cinsiyet Tayini Ve Uygun Mandibula'nın Dizaynı: Retrospektif Çalışma (Doctoral dissertation, Bursa Uludag University (Turkey)) 2020.
28. Ozan, A., & Kitabevleri, N. T. (2004). Nobel Matbaacılık.
29. Altındal F. Intracranial hacim, Basis Cranii Externa yüzey alanı ve Foramen Magnum kesitsel alanı arasındaki ilişki (Master's thesis, Pamukkale Üniversitesi Sağlık Bilimleri Enstitüsü). (2016).
30. Çini NT. Temporal Kemik üzerinde Yer Alan Anatomik oluşumların yüz şekli ile Olan ilişkisinin değerlendirilmesi (Doctoral dissertation, Bursa Uludag University (Turkey)).2021.
31. Arıncı, K. (2005). Arıncı Anatomi. 4. Baskı, Güneş Kitabevi, Ankara.
32. Arifoğlu, Y. (2021). Her Yönüyle ANATOMİ 3. BASKI.
33. Netter, F. H. (2023). Atlas Netter d'anatomie humaine. Elsevier Health Sciences.
34. Sancaklı B. Sinus Paranasales Hacimsel Özelliklerinin İnce Kesit Kraniofasial Bilgisayarlı Tomografi Görüntülerinde İnteraktif Segmentasyonu Yöntemiyle İncelenmesi (Doctoral dissertation, Marmara Üniversitesi (Turkey)).2021.
35. Al Hatmi, AS., Al Ajmi E., Albalushi H., Al Lawati M., Sirasanagandla SR., et al. Anatomical variations of frontal sinus pneumatization: A computed tomography-based study. *F1000Research*, 2023; 12(71), 71.
36. Zinreich SJ., Kennedy DW., Rosenbaum AE., Gayler B., Kumar A., Stammberger H. Paranasal sinuses: CT imaging requirements for endoscopic surgery. *Radiology* 1987; 163: 769-775.
37. Drake, R., Vogl, A. W., & Mitchell, A. W. (2009). Gray's anatomy for students E-book. Elsevier Health Sciences.
38. Öz, M. (2018). Nazal kavite ve paranasal sinüslerin anatomik varyasyonlarının konik ışıklı bilgisayarlı tomografi ile incelenmesi.
39. Ceza Muhakemesi Kanunu Kanun No. 5271, Kabul Tarihi: 4.12.2004.
40. Prachi J. Sex determination in forensic odontology. *J Forensic Odontostomat*. 2012; 23:11- 16.
41. Richardson ER., Malhotra SK. Mesiodistal crown dimension of the permanent dentition of American Negroes. *Am J Orthod*. 1975; 68(2):157-164.
42. Biggerstaff RH. Craniofacial characteristics as determinants of age, sex and race in forensic dentistry. *Dent Clin North Am*. 1977 Jan; 21(1).
43. Yerli Y., Özkoçak V., Koç F. Adli Antropolojide Kimliklendirme Çalışmalarında Yeni Yaklaşımlar. *Journal of Social, Humanities and Administrative Sciences*. 2021; 7(39):846-856.
44. Steadman, D. W., & Haglund, W. D. (2005). The scope of anthropological contributions to human rights investigations. *Journal of forensic sciences*, 50(1), JFS2004214-8.
45. Krishan K, Kanchan T, Passi N, DiMaggio J. Sexual dimorphism in foot length ratios among North Indian adolescents. *J Forensic Leg Med*. 2015; 36.
46. Steyn M., Iscan MY. Sex determination from the femur and tibia in South African Whites. *Forensic Sci Int*. 1997; 90.
47. Kemkes-Grottenthaler A. The reliability of forensic osteology - a case in point case study. *Forensic Sci Int*. 2001; 117.
48. Mahfouz M., Badawi A., Merkl B., Fatah EE., Pritchard E., Kesler K., Moore M., Jantz R., Jantz L. Patella sex determination by 3D statistical shape models and nonlinear classifiers. *Forensic Sci Int*. 2007; 173.
49. Lachenbruch PA, Goldstein M. Discriminant analysis perspectives in biometry. *Biometrics*. 1979; 35(1).

50. Rosing FW., Grawb M., Marre B., RitzTimmed S., Rothschild MA., Rotzscher K., Schmeling A., Schroder I., Geserick G. Recommendations for the forensic diagnosis of sex and age from skeletons. *HOMO*. 2007; 58(1).
51. Iscan MY., Steyn M. Craniometric determination of population affinity in South Africans. *Int J Leg Med*. 1999; 112.
52. Kido, T., Kurata, A., Higashino, H., Sugawara, Y., Okayama, H., Higaki, J., Mochizuki, T. (2007). Cardiac imaging using 256-detector row four-dimensional CT: preliminary clinical report. *Radiation medicine*, 25, 38-44.
53. Recent advances in contrast-enhanced magnetic resonance angiography. Meaney JF, Goyen M. *Eur Radiol*. 2007; 17:2–6.
54. Scarfe WC., Farman AG., What's Cone Beam CT and how does it work? *Dent Clin North Am* 2008; 52(4): 707-730).
55. Demiralp, K. O., Cakmak, S. K., Aksoy, S., Bayrak, S., Orhan, K., & Demir, P. (2019). Assessment of paranasal sinus parameters according to ancient skulls' gender and age by using cone-beam computed tomography. *Folia morphologica*, 78(2), 344-350.,
56. Aktuna Belgin, C., Colak, M., Adiguzel, O., Akkus, Z., & Orhan, K. (2019). Three-dimensional evaluation of maxillary sinus volume in different age and sex groups using CBCT. *European Archives of Oto-Rhino-Laryngology*, 276, 1493-1499.
57. Wanzeler, A. M. V., Alves-Júnior, S. M., Ayres, L., da Costa Prestes, M. C., Gomes, J. T., & Tuji, F. M. (2019). Sex estimation using paranasal sinus discriminant analysis: a new approach via cone beam computerized tomography volume anlysis. *International Journal of Legal Medicine*, 133, 1977-1984.)
58. M. Steyn, E. Pretorius, L. Hutten, "Geometric morphometric analysis of the greater sciatic notch in South Africans ", *HOMO*, 54 (2004).
59. Hennessy RJ. Stringer CB. Geometric morphometric study of the regional variation of modern human craniofacial form. *Am J Phys Anthropol*. 2002; 117.
60. Bauer CM., Niederstatter H., McGlynn G., Stadler H., Parson W. Comparison of morphological and molecular genetic sex-typing on mediaeval human skeletal remains. *Forensic Sci Int Gen*. 2013; 7.
61. Flasiński, M. (2016). Introduction to artificial intelligence. Springer.
62. Engin S. 2021 Python ile Makine Öğrenmesi. Nisan 2021. Abaküs.
63. Diri, B. (2014). Makine Öğrenmesine Giriş. Retrieved from Lecture Notes Online Web site: <https://www.ce.yildiz.edu.tr/personal/banud/file/2634/Makine+Ogrenmesi-ML-10.pdf>.
64. Samuel A., Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*. 1959;3(3):210-229.
65. Ahmed Z., Mohamed K., Zeeshan S. ve Dong X Artificial intelligence with multi-functional machine learning platform development for better healthcare and precision medicine. *Database*, 2020; 1- 35.
66. Mekov E., Miravittles M. ve Petkov R. Artificial intelligence and machine learning in respiratory medicine. *Expert Review of Respiratory Medicine*. 2020; 14(6), 559-564.
67. Topal E. Apertura piriformis, sinus paranasales ve cranium boyutlarının karşılaştırılması (Master's thesis, İstanbul Medipol Üniversitesi Sağlık Bilimleri Enstitüsü).2019.
68. Karakoyun M., Hacibeyoğlu M. Biyomedikal Veri Kümeleri ile Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması.DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi. 2014; Cilt: 16 Sayı: 48 sh. 30-41.
69. Krems RV. Bayesian machine learning for quantum molecular dynamics. *Phys Chem Chem Phys*. 2019; 21(25):13392-13410.
70. ALSAADAWI, M. A. W. (2023). Detection of Thyroid Disease Using Machine Learning Models (Doctoral dissertation).
71. Pınar M., Okumuş O., Turgut U. O., Kalıpsız O., Aktaş MS., et al. Büyük veri içeren öneri sistemleri için hiperparametre optimizasyonu. *Ulusal Yazılım Mühendisliği Sempozyumu*, 2017; 22, 272.
72. Bircan, H. (2004). Lojistik regresyon analizi: Tıp verileri üzerine bir uygulama. *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*, (8), 185-208.
73. Senel, S., & Alatlı, B. (2014). A review of articles used logistic regression analysis. *Journal of Measurement and Evaluation in Education and Psychology-EPOD*, 5(1), 35-52.

74. Ray S., A quick review of machine learning algorithms. In 2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon) (pp. 35-39). IEEE.
75. Cortes C., Vapnik V., Support-Vector Networks. Machine Learning. 1995; 20:273-297.
76. Vlacic, L. (2002). Learning and Soft Computing, Support Vector Machines, Neural Networks, and Fuzzy Logic Models, Vojislav Kecman; MIT Press, Cambridge, MA, 2001, ISBN 0-262-11255-8, 2001, pp. 578. Neurocomputing, 47(1-4), 305-307.
77. Tektaş N., Classification performance comparison of discriminant analysis and logistic regression analysis. Turkish Studies International Periodical For The Languages, Literature and History of Turkish or Turkic. 2014; 9(2):1517-1527.
78. Scikit-learn [Internet]. Scikit-learn: Python'da Makine Öğrenimi. [alıntılanma tarihi: 18 Mayıs 2023]. Erişim adresi: <https://scikit-learn.org/stable/>.
79. Pal M., Random forest classifier for remote sensing classification. International Journal of Remote Sensing. 2005; 26(1):217-222.
80. Stoltzfus JC. Logistic Regression: A Brief Primer. Academic Emergency Medicine. 2011; 18:1099-1104.
81. Kurt İ., Makine öğrenmesi yöntemleri kullanılarak sesin müzikal öznelilikleri ile parkinson hastalığının tespiti (Master's thesis, Trakya Üniversitesi Fen Bilimleri Enstitüsü). 2019.
82. Aydın, C. (2018). Makine öğrenmesi algoritmaları kullanılarak itfaiye istasyonu ihtiyacının sınıflandırılması. Avrupa Bilim ve Teknoloji Dergisi, (14), 169-175.
83. Bristow J., Simms Z., Randolph-Quinney PS. Taphonomy. In: Black S, Ferguson E (eds). Forensic Anthropology 2000-2010. Boca Raton, FL: CRC Press; 2011. pp. 279-318.
84. Özer İ., İnsan İskeletlerinde Cinsiyet Tahmini. Türkiye Klinikleri J Foren Med-Special Topics. 2017; 3(1):38-42.
85. Gómez-Valdés JA., Ramírez GT., Molgado SB., Sain-Leu PH., Caballero JLC., Sanchez-Mejorada G. Discriminant Function Analysis for Sex Assessment in Pelvic Girdle Bones: Sample from the Contemporary Mexican Population. Journal of Forensic Sciences. 2011; 56(2):297-301.
86. AYTEK, A. İ. (2017). Geometrik morfometri. Masrop E-Dergi, 11(17), 1-7.
87. Krogman WM. Iscan MY., The Human Skeleton in Forensic Medicine. 1986. 2nd Edition, Charles C. Thomas, Springfield.
88. Steyn M., Metric sex determination from the pelvis in modern Greeks. Forensic Science International. 2008; 179(1), 86.e1-86.e6.
89. Mahakkanukrauh P., Ruengdit S., Tun MS., Case DR., Sinthubua A., Osteometric sex estimation from the os coxa in a Thai population. Forensic Science International. 2017; 271(127), e1-e7.
90. Tetiker H., Gençer CU., 3 Boyutlu Bilgisayarlı Tomografi ile 3B Rendering Tekniği Kullanarak Skapula Ölçümlerinden Anadolu Popülasyonunda Cinsiyet Tahmini. The Bulletin of Legal Medicine; 2020; 25:223-229.
91. Cekdemir, Y.E., Estimation of sex using morphometric measurements performed on cranial computerized tomography scans. La radiologia medica. 2021; 126, pp. 306-315.
92. Dereli A.K., Sex determination with morphological characteristics of the skull by using 3D modeling techniques in computerized tomography. Forensic Science, Decker Medicine, and Pathology. 2018; 14, pp. 450-459.
93. Cohen O., Warman M., Fried M., Shoffel-Havakuk H., Adi M., Halperin D., Lahav Y., et al. Volumetric analysis of the maxillary, sphenoid and frontal sinuses: a comparative computerized tomography based study. Auris Nasus Larynx, 2018; 45(1), 96-102.
94. Ajanovic, Z., Dervisevic, L., Dervisevic, A., Sarac-Hadzihalilovic, A., Dervisevic, E., Biscević Tokic, J., Prasko, S. (2022). Sex prediction by geometric morphometric analysis of the hard palate. European Review for Medical & Pharmacological Sciences, 26(17).
95. Bharath, S. T., Kumar, G. R., Dhanapal, R., & Saraswathi, T. R. (2011). Sex determination by discriminant function analysis of palatal rugae from a population of coastal Andhra. Journal of Forensic Dental Sciences, 3(2), 58.
96. Pinskerova, V., Nemec, K., & Landor, I. (2014). Gender differences in the morphology of the trochlea and the distal femur. Knee Surgery, Sports Traumatology, Arthroscopy, 22(10), 2342-2349.

97. Marinescu, M., Panaitescu, V., Rosu, M., Maru, N., & Punga, A. (2014). Sexual dimorphism of crania in a Romanian population: Discriminant function analysis approach for sex estimation. *Rom J Leg Med*, 22(1), 21-26.
98. Manoel, C., Prado, F. B., Caria, P. H. F., & Groppo, F. C. (2017). Morphometric analysis of the foramen magnum in human skulls of Brazilian individuals: its relation to gender. *Journal of Morphological Sciences*, 26(2), 0-0.
99. Gillespie, R. J., Levine, A., Fitzgerald, S. J., Kolaczko, J., DeMaio, M., Marcus, R. E., & Cooperman, D. R. (2011). Gender differences in the anatomy of the distal femur. *The Journal of Bone & Joint Surgery British Volume*, 93(3), 357-363.
100. Teke, H. Y., Duran, S., Canturk, N., Canturk, G. (2007). Determination of gender by measuring the size of the maxillary sinuses in computerized tomography scans. *Surgical and radiologic anatomy*, 29, 9-13.
101. Hamd, Z. Y., Aljuaid, H., Alorainy, A. I., Osman, E. G., Abuzaid, M., Elshami, W., Ahmed, W. (2023). Machine learning as new approach for predicting of maxillary sinus volume, a sexual dimorphic study. *Journal of Radiation Research and Applied Sciences*, 16(2), 100570.
102. Bangi, B. B., Ginjupally, U., Nadendla, L. K., & Vadla, B. (2017). 3D evaluation of maxillary sinus using computed tomography: A sexual dimorphic study. *International journal of dentistry*, 2017.
103. Tiwari, S. T., U, S., & MM, J. (2022). Gender determination by measuring maxillary sinus volume using computed tomography. *Journal of Health and Allied Sciences NU*, 13(01), 064-072.
104. Ekizoglu O., Inci E., Hocaoglu E., Sayin I., Kayhan F.T., Can I.O., et al. The use of maxillary sinus dimensions in gender determination: a thin-slice multidetector computed tomography assisted morphometric study. *Journal of Craniofacial Surgery*, 2014; 25(3), 957-960.
105. Toy, S., Secgin, Y., Oner, Z., Turan, M. K., Oner, S., & Senol, D. (2022). A study on sex estimation by using machine learning algorithms with parameters obtained from computerized tomography images of the cranium. *Scientific Reports*, 12(1), 4278.
106. Meyvacı, S. S., Bulut, D. G., Öztürk, A. T., & Ankaralı, H. Gender estimation from angular parameters of mandible in Turkish adults. *Batı Karadeniz Tıp Dergisi*, 5(2), 240-247.
107. Kartal E., Etili Y., Asirdizer M., Hekimoglu Y., Keskin S., Demir U., Yavuz A., Celbis O., Sex estimation using foramen magnum measurements, discriminant analyses and artificial neural networks on an eastern Turkish population sample. *Leg Med (Tokyo)*. 2022 Nov; 59:102143.
108. Neelaveni J., Devasana M.G., Alzheimer disease prediction using machine learning algorithms. In 2020 6th International Conference on Advanced Computing and Communication Systems (ICACCS), (2020, March), (pp. 101-104). IEEE.
109. Nurzynska, K., Piórkowski, A., Strzelecki, M., Kociolek, M., Banyś, RP ve Obuchowicz, R. (2024). Omurga gövdesi BT taramalarında yaş ve cinsiyetin ayırt edilmesi – Doku analizi ve derin öğrenme yaklaşımı. *Biyosiberetik ve Biyomedikal Mühendisliği*, 44 (1), 20-30.
110. Pisharody A.S., Pargaonkar S., Kulkarni V.Y., et al. Fingerprint classification and building a gender prediction model using random forest algorithm. *International Journal of Knowledge Engineering and Data Mining*, 2015; 3(3-4), 286-298.
111. Leavitt, L., Volovic, J., Steinhauer, L., Mason, T., Eckert, G., Dean, J. A., Turkkahraman, H. (2023). Can we predict orthodontic extraction patterns by using machine learning? *Orthodontics & Craniofacial Research*, 26(4), 552-559.
112. Etili, Y., Asirdizer, M., Hekimoglu, Y., Keskin, S., Yavuz, A. (2019). Yaş ve cinsiyete göre eşit dağılmış bir popülasyonda ayırıcı analizler ve sinir ağları ile sakrum ve kuyruk sokumundan cinsiyet tahmini. *Uluslararası adli bilimler*, 303, 109955.
113. Curate F., Umbelino C., Perinha A., Nogueira C., Silva A.M., Cunha E. Sex determination from the femur in Portuguese populations with classical and machine-learning classifiers. *J Forensic Leg Med*. 2017; 52:75-81.
114. Ataş, I. (2022). Human gender prediction based on deep transfer learning from panoramic dental radiograph images. *Traitement du Signal* 39 (5), 1585.

- 115.Ortiz, A. G., Costa, C., Silva, R. H. A. D., Biazevic, M. G. H., & Michel-Crosato, E. (2020). Sex estimation: Anatomical references on panoramic radiographs using Machine Learning. *Forensic Imaging*, 20, 200356.
- 116.Amin, W., Othman, D. (2014). Gender dimorphism of crania in young Jordanian adults: discriminant function analysis approach for gender prediction. *Journal of Current Surgery*, 4(3), 76-85.
- 117.Vila-Blanco, N., Vilas, RR, Carreira, M. J. and Tomás, I. (2020). Towards deep learning reliable gender prediction from dental panoramic radiographs. In *Proceedings of the 9th European Startup Artificial Intelligence Researchers Symposium, co-located with the 24th European Conference on Artificial Intelligence (ECAI 2020) (Volume 2655)*.
- 118.Öner, S., Turan, M., Öner, Z. (2021). Estimation of gender by using decision tree, a machine learning algorithm, with patellar measurements obtained from MDCT images. *Medical Records*, 3(1), 1-9.
- 119.Diac, M. M., Toma, G. M., Damian, S. I., Fotache, M., Romanov, N., Tabian, D., ... & Iliescu, D. B. (2023). Machine Learning Models for Prediction of Gender Based on Lumbar Vertebral Morphometry.
- 120.Nogueira L., Santos F., Castier F., Sex assessment using the radius bone in a French sample when applying various statistical models. *Int J Legal Med.* 2023; 137(4):925-934.



8. EKLER

EK 1

 **BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ GİRİŞİMSSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU ONAYI**
BOLU ABANT İZZET BAYSAL UNIVERSITY NON-INTERVENTIONAL CLINICAL RESEARCH ETHICS COMMITTEE APPROVAL

Sayı : 87
Konu: Kararlar

19.4/2024

BAŞVURU BİLGİLERİ (APPLICATION INFORMATION)	ARAŞTIRMANIN ADI (TITLE OF THE PROJECT)	Bilgisayarlı tomografi görüntülerinden morфометrik ölçümlerin erişkin bireylerin cinsiyet tayininde kullanılabilirliğinin değerlendirilmesi.
	ARAŞTIRMANIN İNGİLİZCE ADI (TITLE OF THE PROJECT)	Evaluation of the usability of morphometric measurements from computed tomography images in gender determination of adult individuals.
	SORUMLU ARAŞTIRMACI (PRINCIPAL INVESTIGATOR)	Dr.Öğr.Üyesi Murat DIRAMALI
	DİĞER ARAŞTIRMACILAR (OTHER INVESTIGATORS)	Yük.Lis.Öğr.Hilal IŞIK ROZAN, Doç.Dr.Seval BAYRAK
	ARAŞTIRMA MERKEZİ (RESEARCH CENTER)	Bolu Abant İzzet Baysal Üniversitesi Diş Hekimliği Fakültesi

KARAR (DECISION)	Karar no (Decision No): 2024/81	Tarih (Date) 02.04.2024
		Dr.Öğr.Üyesi Murat DIRAMALI'nın sorumluluğunda yapılması tasarlanan ve yukarıda başvuru bilgileri verilen araştırma dosyası ve ilgili belgelerin incelenmesi sonucunda araştırmanın gerçekleştirilmesinde etik yönden sakınca olmadığına mevcudun oy birliği/oy çokluğu ile karar verilmiştir.

Üyeler	Uzmanlık alanı	Kurumu	İmzası
Prof. Dr. Akif Hakan KURT (Başkan)	Farmakoloji	BAİBÜ Tıp Fakültesi	
Prof. Dr. Mehmet Hayri ERKOL (Başkan Yardımcısı)	Genel Cerrahi	BAİBÜ Tıp Fakültesi	
Prof. Dr. Aslı ÇELEBİ TAYFUR (Üye)	Çocuk Sağlığı Hastalıkları /Nefroloji Bilim Dalı	BAİBÜ Tıp Fakültesi	
Doç. Dr. Tuba TASLAMACIOĞLU DUMAN (Üye)	İç Hastalıkları Anabilim Dalı	BAİBÜ Tıp Fakültesi	
Doç. Dr. Kübra DEĞİRMENCI (Üye)	Protetik Diş Tedavisi	BAİBÜ Diş Hekimliği Fakültesi	
Doç. Dr. Birgül CERİT (Üye)	Hemşirelik Bölümü	BAİBÜ Sağlık Bilimleri Fakültesi	
Dr. Öğr. Üyesi Tuğba KOCAĞA (Üye)	Antrenörlük Eğitimi	BAİBÜ Spor Bilimleri Fakültesi	
Dr.Öğr.Üyesi Oya KALAYCIOĞLU (Raportör)	Biyoistatistik	BAİBÜ Tıp Fakültesi	
Av. Huri Hülya GÜNEŞ COŞKUN (Üye)	Avukat	Özel Hukuk Bürosu (BOLU)	