T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

PANORAMİK DİŞ RÖNTGENLERİNDEN DİŞ EKSİKLİKLERİNİN MAKİNE ÖĞRENMESİ KULLANILARAK TESPİTİ ve SINIFLANDIRILMASI

Nurefşan GÜZELCE KUYULU

DANIŞMAN
Doç. Dr. Sibel SENAN

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı

Haziran, 2025

TEZ KABUL VE ONAYI

Nurefşan GÜZELCE KUYULU tarafından, **Doç. Dr. Sibel SENAN** danışmanlığında hazırlanan **"PANORAMİK DİŞ RÖNTGENLERİNDEN DİŞ EKSİKLİKLERİNİN MAKİNE ÖĞRENMESİ KULLANILARAK TESPİTİ ve SINIFLANDIRILMASI"** başlıklı bu çalışma, jürimiz tarafından **16/06/2025** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Doç. Dr.Sibel SENAN İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Bilimleri Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Prof. Dr. Muhammed Ali AYDIN İstanbul Üniversitesi-Cerrahpaşa Siber Güvenlik Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi Oğuzhan ÖZTAŞ İstanbul Gelişim Üniversitesi Bilgisayar Bilimleri Anabilim Dalı		☒ Kabul ☐ Ret

İTHAF

Aileme ithaf ediyorum…

BÜTÇE DESTEKLERİ

PANOROMİK DİŞ RÖNTGENLERİNDEN DİŞ EKSİKLİKLERİNİN MAKİNE ÖĞRENMESİ KULLANILARAK TESPİTİ ve SINIFLANDIRILMASI

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Tez sürecim boyunca bilgi ve deneyimiyle yolumu aydınlatan, her aşamada desteğini hissettiren değerli hocam Doç. Dr. Sibel SENAN'a teşekkürlerimi sunarım.

Haziran 2025 **Nurefşan GÜZELCE KUYULU**

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
İTHAF ..... **iv**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **xi**
KISALTMA LİSTESİ ..... **xii**
ÖZET ..... **xiii**
ABSTRACT ..... **xv**
1. GİRİŞ **1**
2. KAVRAMSAL ÇERÇEVE **4**
3. YÖNTEM **8**
3.1. VERİ SETİ 8
Veri Sınıflandırma 9
3.1. VERİ HAZIRLAMA 18
Veri Arttırma 18
3.2. KULLANILAN MODELLER 22
CNN Mimarileri 23
Makine Öğrenimi Modelleri 24
3.3. MODEL TASARIMI 25
4. BULGULAR **26**
4.1. PERFORMANS METRİKKLERİ 27
4.2. CNN MODELLERİNİN ANALİZ SONUÇLARI 28
Gerçek Veri Seti İçin CNN Modellerinin Analiz Sonuçları 28
Hibrit Veri Seti İçin CNN Modellerinin Analiz Sonuçları 30
4.3. MAKİNE ÖĞRENİMİ SINIFLANDIRICILARININ ANALİZ SONUÇLARI 33
SVM Sınıflandırıcısının Analiz Sonuçları 33
KNN Sınıflandırıcısının Analiz Sonuçları 39
RF Sınıflandırıcısının Analiz Sonuçları 45
XGB Sınıflayıcısının Analiz Sonuçları 51
Modellerin Performans Analizi 57

5. TARTIŞMA **59**
6. SONUÇ VE ÖNERİLER **60**
KAYNAKLAR **62**
İNTİHAL RAPORU İLK SAYFASI **67**
ETİK KURUL İZİN YAZISI **70**
KURUM İZNİ YAZILARI **72**
ÖZGEÇMİŞ **80**

ŞEKİL LİSTESİ

Sayfa No

Şekil 3.1: Gerçek Veri Seti'ne ait örnek veri; alt çenede eksik dişler, implant için uygun(au) 13

Şekil 3.2: Gerçek Veri Seti'ne ait örnek veri; alt çenede eksik dişler, implant için uygun değil(ad) 13

Şekil 3.3: Gerçek Veri Seti'ne ait örnek veri; üst çenede eksik dişler, implant için uygun(uu) 14

Şekil 3.4: Gerçek Veri Seti için üst çenede eksik dişler, implant için uygun değil(ud) 14

Şekil 3.5: Gerçek Veri Seti'ne ait örnek veri; her iki çenede eksik dişler, implant için uygun(auu) 15

Şekil 3.6: Gerçek Veri Seti'ne ait örnek veri; her iki çenede eksik dişler, implant için uygun değil(aud) 15

Şekil 3.7: Hibrit Veri Seti'ne ait örnek veri; alt çenede eksik dişler, implant için uygun(au) . 16

Şekil 3.8: Hibrit Veri Seti'ne ait örnek veri; alt çenede eksik dişler, implant için uygun değil(ad) 16

Şekil 3.9: Hibrit Veri Seti'ne ait örnek veri; üst çenede eksik dişler, implant için uygun(uu) 17

Şekil 3.10: Hibrit Veri Seti'ne ait örnek veri; üst çenede eksik dişler, implant için uygun değil(ud) 17

Şekil 3.11: Hibrit Veri Seti'ne ait örnek veri; her iki çenede eksik dişler, implant için uygun(auu) 18

Şekil 3.12: Hibrit Veri Seti'ne ait örnek veri; her iki çenede eksik dişler, implant için uygun değil(aud) 18

Şekil 3.13: Genel CNN mimarisi 23

Şekil 3.14: Önerilen çalışmanın genel tasarımı 25

Şekil 4.1: Gerçek Veri Seti için CNN modellerinin karışıklık(confusion) matrisleri 28

Şekil 4.2: Hibrit Veri Seti için CNN modellerinin karışıklık(confusion) matrisleri 31

Şekil 4.3: Gerçek Veri Seti için SVM sınıflandırıcısının karışıklık(confusion) matrisleri 34

Şekil 4.4: Hibrit Veri Seti için SVM sınıflandırıcısının karışıklık(confusion) matrisleri.....37

Şekil 4.5: Gerçek Veri Seti için KNN sınıflandırıcısının karışıklık(confusion) matrisleri.....40

Şekil 4.6: Hibrit Veri Seti için KNN sınıflandırıcısının karışıklık(confusion) matrisleri.....43

Şekil 4.7: Gerçek Veri Seti için RF sınıflandırıcısının karışıklık(confusion) matrisleri.....46

Şekil 4.8: Hibrit Veri Seti için RF sınıflandırıcısının karışıklık(confusion) matrisleri.....49

Şekil 4.9: Gerçek Veri Seti için XGB sınıflandırıcısının karışıklık(confusion) matrisleri.....52

Şekil 4.10: Hibrit Veri Seti için XGB sınıflandırıcısının karışıklık(confusion) matrisleri.....55

Şekil 4.11: Gerçek Veri Seti için Modellerin performans oranları.....57

Şekil 4.12: Hibrit Veri Seti için Modellerin performans oranları.....58

TABLO LİSTESİ

Sayfa No

Tablo 2.1: İmplant planlama ve diş eksikliği tespiti üzerine yapılan çalışmaların veri seti adı, veriseti türü ve veri sayısı yönünden incelemesi 5

Tablo 2.2: İmplant planlama ve diş eksikliği tespiti üzerine yapılan çalışmaların model ve performans yönünden incelemesi 6

Tablo 3.1: Gerçek Veri Setine ait Sınıflar ve içerdikleri veri sayıları 11

Tablo 3.2: Hibrit veri setine ait sınıflar ve içerdikleri veri sayıları 12

Tablo 3.3: Gerçek Veri Seti için klasörlerin kısa adı, içerdikleri veri sayısı, arttırılmış veri vayıları ve eğitim, doğrulama, test içn kullanılan veri sayılarının gösterimi 21

Tablo 3.4: Hibrit Veri Seti için klasörlerin kısa adı, içerdikleri veri sayısı, arttırılmış veri vayıları ve eğitim, doğrulama, test içn kullanılan veri sayılarının gösterimi 21

Tablo 3.5: CNN modelleri ve ML sınıflandırıcılarının parametre değerleri 26

Tablo 4.1: Gerçek Veri Seti için CNN modellerinin karışıklık matrisi sonuçları 29

Tablo 4.2: Hibrit Veri Seti için CNN modellerinin karışıklık matrisi sonuçları 32

Tablo 4.3: Gerçek Veri Seti için SVM sınıflandırıcısının karmaşıklık matrisi sonuçları 35

Tablo 4.4: Hibrit Veri Seti için SVM sınıflandırıcısının karmaşıklık matrisi sonuçları 38

Tablo 4.5: Gerçek Veri Seti için KNN sınıflandırıcısının karmaşıklık matrisi sonuçları 41

Tablo 4.6: Hibrit Veri Seti için KNN sınıflandırıcısının karmaşıklık matrisi sonuçları 44

Tablo 4.7: Gerçek Veri Seti için RF sınıflandırıcısının karmaşıklık matrisi sonuçları 47

Tablo 4.8: Hibrit Veri Seti için RF sınıflandırıcısının karmaşıklık matrisi sonuçları 50

Tablo 4.9: Gerçek Veri Seti için XGB sınıflandırıcısının karmaşıklık matrisi sonuçları.....53

Tablo 4.10: Hibrit Veri Seti içinXGB sınıflandırıcısının karmaşıklık matrisi sonuçları.....56

KISALTMA LİSTESİ

Kısaltmalar	Açıklama
AD	: Alt çenede diş eksikliği bulunan ancak implant tedavisine uygun olmayangörüntüler
AU	: Alt çenede diş eksikliği bulunan ve implant tedavisine uygun olan görüntüler
UD	: Üst çenede diş eksikliği bulunan ancak implant tedavisine uygun olmayan görüntüler
UU	: Üst çenede diş eksikliği bulunan ve implant tedavisine uygun olan görüntüler
AUD	: Hem alt hem üst çenede diş eksikliği bulunan ve implant tedavisine uygun olmayan görüntüler
AUU	: Hem alt hem üst çenede diş eksikliği bulunan ve implant tedavisine uygun olan görüntüler
CNN	**:** Evrişimli Sinir Ağı
KNN	**:**K-Nearest Neighbors
Mask-RCNN	:Mask Bölgesel Evrişimli Sinir Ağı
SVM	**:**Support Vector Machine
YZ	**:**Yapay zeka
XGB	**:**XGBoost

ÖZET

YÜKSEK LİSANS TEZİ

PANORAMİK DİŞ RÖNTGENLERİNDEN DİŞ EKSİKLİKLERİNİN MAKİNE ÖĞRENMESİ KULLANILARAK TESPİTİ ve SINIFLANDIRILMASI

Nurefşan GÜZELCE KUYULU

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı

Danışman : Doç. Dr. Sibel SENAN

Dijital teknolojiler ve yapay zekâ (YZ) tarafından yönlendirilen diş hekimliği araştırmalarındaki son gelişmeler, tanı ve tedavi planlamasını kökten değiştirmektedir. İnsan benzeri yeteneklere sahip olan YZ, diş hekimliği alanında özellikle dönüştürücü bir rol oynamakta; hassas analizler ve kişiselleştirilmiş tedavi seçenekleri sunmaktadır. Panoramik radyograflarda YZ, erken hastalık tespiti ve tedavi optimizasyonu için kritik bir araç olarak öne çıkmaktadır.

Bu tez çalışması, diş sağlığı alanında YZ tabanlı bir klinik karar destek sistemi önermeyi amaçlamaktadır. Bu amaçla, makine öğrenmesi teknikleri kullanılarak, panoramik diş radyografları—üzerinde eksik dişler ve bu bölgelere implant yerleştirme uygunluğu belirlenecektir. Bu doğrultuda, açık erişimli iki veri kümesi kullanılarak ve işlenerek oluşturulan yeni bir veri seti ve Sağlık Bilimleri Üniversitesi Hamidiye Diş Hekimliği Fakültesi'nden temin edilen hasta panoramik radyografi görüntülerinden oluşan gerçek veri seti kullanılmıştır. Farklı makine öğrenmesi teknikleri ve hibrit mimariler bu veri setleri üzerinde uygulanarak ve sergiledikleri performans sonuçları analiz edilerek ele alınan probleme en uygun akıllı yaklaşıma dair bir değerlendirme ortaya konulmuştur. Değerlendirme sonucunda

önerilen bu bilgisayar destekli tanı sistemin diş hekimliğinde hasta bakımı ve tedavi karar verme süreçlerini desteklemesi beklenmektedir.

Haziran 2025 , 96 sayfa.

Anahtar kelimeler: Yapay zeka, makine öğrenmesi, derin öğrenme, karar destek sistemleri, eksik diş tespiti, implant planlama, panoramik radyografi

ABSTRACT

M.Sc. THESIS

DETECTION AND CLASSIFICATION OF DENTAL DEFICIENCIES FROM PANORAMIC DENTAL X-RAYS USING MACHINE LEARNING

Nurefşan GÜZELCE KUYULU

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Computer Engineering

Defence Technology (Master) (With Thesis)

Supervisor : Assoc. Prof. Dr. Sibel SENAN

Recent advancements in dental research driven by digital technologies and artificial intelligence (AI) have radically transformed diagnostic and treatment planning processes. AI, possessing human-like capabilities, plays a particularly transformative role in the field of dentistry by enabling precise analysis and personalized treatment options. In panoramic radiographs, AI emerges as a critical tool for early disease detection and treatment optimization.

This thesis aims to propose an AI-based clinical decision support system in the field of dental health. To achieve this, missing teeth and the suitability of implant placement in these regions will be identified using machine learning techniques applied to panoramic dental radiographs. Accordingly, two publicly available datasets were combined and processed to create a new dataset, along with a real dataset composed of patient panoramic radiographic images obtained from Hamidiye Faculty of Dentistry, University of Health Sciences. Various machine learning techniques and hybrid architectures were applied to these datasets, and their performance results were analyzed to determine the most suitable intelligent approach to the problem. As a result

of the evaluation, the proposed computer-aided diagnostic system is expected to support patient care and treatment decision-making processes in dentistry.]

June 2025, [96] pages.

Keywords: [Artificial intelligence, machine learning, deep learning, decision support systems, missing tooth detection, implant planning, panoramic radiography]

1. GİRİŞ

Günümüz diş hekimliği araştırmalarında, dijital teknolojiler ve yapay zekâ (YZ) sayesinde önemli ilerlemeler kaydedilmiştir. Yapay zekâ, bilgisayar sistemlerinin veri analizi, örüntü tanıma ve karar verme gibi karmaşık görevleri yerine getirmesini sağlamakta; aynı zamanda karar verme süreçlerini hızlandırmakta, bu kararların kalitesini iyileştirmekte ve genel performans üzerinde olumlu etkiler yaratmaktadır [1].

YZ son yıllarda tıp alanında da kritik bir araç hâline gelmiş olup özellikle erişkin hastalıklara ilişkin analizlerde, YZ'nin sağladığı ilerlemeler dikkat çekicidir. YZ, hasta sağlık verilerinin daha hızlı ve etkin bir biçimde analiz edilmesine olanak sağlayarak kişiselleştirilmiş tedavi planlarının oluşturulmasını, hastalıkların erken teşhisini, tıbbi görüntülemenin geliştirilmesini ve daha hassas tedavi uygulamalarını mümkün kılmaktadır. Büyük veri analitiği, makine öğrenmesi ve derin öğrenme gibi YZ yöntemleri, tanı ve tedavi süreçlerinin doğruluğunu, hızını ve etkinliğini artırmaktadır. Bu yöntemler, klinik ve genomik verileri entegre ederek hastalıkların doğru teşhisine ve hasta prognozunun güvenilir bir şekilde tahmin edilmesine olanak tanımaktadır [2, 3]. Ayrıca, YZ, nadir hastalıkların tanı ve tedavisinde de önemli bir rol oynamaktadır [4].

Diş hekimliği alanında da YZ, hastalıkların tanı ve tedavisinde önemli bir araç hâline gelmiştir. Yapay zekâ tabanlı sistemler, diş hekimliği alanında önemli ilerlemelere öncülük etmektedir. Özellikle derin öğrenme, çeşitli dental durumların tanımlanması ve sınıflandırılmasının otomatikleştirilmesinde kullanılarak tanısal doğruluğu ve etkinliği artırmaktadır.

Örneğin, Evrişimli Sinir Ağları (CNN) ile Destek Vektör Makineleri'nin (SVM) kombinasyonu, çürükler, periodontal kemik yüksekliğinde değişimler ve gömülü üçüncü azı dişleri gibi anomalilerin tespitinde geleneksel yöntemlere kıyasla daha başarılı sonuçlar elde edilmesini sağlamıştır [5]. Derin öğrenme modelleri arasında YOLOv3, çürükler ve kanal tedavileri gibi yaygın sorunları %99,33 doğrulukla sınıflandırırken [6],

U-Net modeli çürük tanısında %94 doğruluk oranı ile etkili sonuçlar vermiştir [7]. Ayrıca, lokal adaptif eşikleme ve SVM gibi yöntemlerle geliştirilen makine öğrenmesi algoritmaları, dental restorasyonların otomatik olarak yüksek doğrulukla tespit ve sınıflandırılmasında kullanılmaktadır [8]. Derin öğrenme modelleri karşılaştırıldığında, YOLOv2 modeli özellikle üçüncü azı dişi açılarının tespitinde %99'a varan doğrulukla öne çıkmaktadır [9].

YZ modellerinin performansına yönelik araştırmalar, bu teknolojilerin çeşitli diş hekimliği uygulamalarındaki faydalarını ortaya koymuştur. Bu uygulamalar arasında diş rengi seçimi, restorasyon tasarımının otomasyonu, diş preparasyon sınırlarının belirlenmesi, döküm süreçlerinin optimize edilmesi, hareketli protez kullanan hastalarda yüz değişimlerinin öngörülmesi ve hareketli bölümlü protezlerin tasarımı yer almaktadır [10]. Panoramik diş röntgenlerinde diş eksikliklerinin tespiti ve sınıflandırılmasına yönelik makine öğrenmesi çalışmaları da hızla gelişmektedir.

Çalışma, literatürdeki diğer çalışmalardan farklı bir yaklaşım sergileyerek henüz yeterince ele alınmamış bir alanı hedeflemektedir. Mevcut çalışmaların büyük bir kısmı diş tespiti, sınıflandırma ve çeşitli dental hastalıkların saptanması üzerine odaklanmıştır. Örneğin, bir çalışmada Mask Bölgesel Evrişimli Sinir Ağı (Mask-RCNN) algoritması kullanılarak diş segmentasyonu yapılmış ve dental süreçlerin otomasyonu amaçlanmıştır; benzer şekilde çürük ve periapikal lezyonların değerlendirilmesi, dental radyograflardan cinsiyet tayini ve dental anomalilerin tespiti gibi konular da çalışılmıştır [11-14]. Diş çürüğünün saptanması [15,16], otomatik diş tespiti ve tanımlanması [17, 18, 19, 20, 21, 22, 23, 24], dental restorasyonların otomatik olarak sınıflandırılması [10, 25], periodontal hastalıkların erken tanısı ve periodontal defektlerin teşhisi [26], mesiodens saptanması [27], mineralleşmiş dokuların yapısı ve dental hastalıkların nedenlerinin anlaşılması [28] ve farklı modelleme teknikleriyle diş segmentasyonu [29, 30, 31] gibi pek çok konu üzerine çeşitli çalışmalar mevcuttur.

Bu tez çalışması, hastalara ait eksik dişlerin radyografik değerlendirme yoluyla tespit edilmesini sağlayan, klinik karar verme süreçlerini destekleyecek bir bilgisayar destekli tanı sistemi geliştirmeyi amaçlamaktadır. Bu amaçla, panoramik dental

radyograflarda eksik dişlerin tespit edilmesi ve bu bölgelerin implant yerleştirilmesine uygunluklarının değerlendirilmesi için derin öğrenme tabanlı bir sistem geliştirilmesi hedeflenmektedir. Bu sistemin geliştirilmesinde iki ayrı veri seti kullanılmıştır. İlk veri seti, İstanbul Sağlık Bilimleri Üniversitesi Hamidiye Diş Hekimliği Fakültesi'nden temin edilen ve 18 yaş üzeri bireylere ait panoramik dental radyograflardan oluşan veri kümesidir. İkinci veri seti ise, "Teeth Segmentation Dataset" (Humans in the Loop, 2025) ve "Dental Dataset" (Hexthext, 2023) adlı iki açık erişimli veri setinin birleştirilmesi ve işlenmesi ile oluşturulan veri kümesidir. Farklı model mimarileri her iki veri seti üzerinde ayrı ayrı analiz edilerek değerlendirilmiş; eksik dişlerin doğru şekilde tespiti ve implant açısından uygunluğunun belirlenmesinde bu mimarilerinin performansı karşılaştırmalı olarak incelenmiştir. Sonuç olarak, en yüksek performansı sergileyen sistem modeli ortaya konmuştur.

Önerilen sistem, panoramik dental radyograflarda dişsiz alanları otomatik olarak tanımlayacak ve bu bölgeleri, özellikle implant uygulamalarına uygunluk açısından sınıflandıracaktır. Bu doğrultuda, makine öğrenmesine dayalı bir çerçeve oluşturularak yalnızca eksik dişlerin tespiti değil, aynı zamanda implant yerleşimi için bu alanların mekânsal uygunluğu da değerlendirilecektir. Bu yaklaşım sayesinde, tanı doğruluğunun artırılması, klinik iş yükünün azaltılması ve akıllı diş sağlığı sistemlerinin geliştirilmesine katkı sağlanması hedeflenmektedir.

Tez çalışmasında iki farklı analiz çalışması yürütülmüştür:

- İlk analizde dört farklı evrişimli sinir ağı (CNN) mimarisi olan DenseNet201, InceptionV3, MobileNetV2 ve Xception modelleri Gerçek ve Hibrit veri setleri ile ayrı ayrı eğitilmiş ve test edilmiştir.
- İkinci analizde ise bu modeller öznitelik çıkarıcı (feature extractor) olarak da kullanılmış, elde edilen öznitelikler daha sonra geleneksel makine öğrenmesi algoritmaları olan Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Random Forest (RF) ve XGBoost (XGB) ile sınıflandırılmıştır.

Bu sayede, hem doğrudan CNN tabanlı sınıflandırma performansı hem de CNN destekli geleneksel makine öğrenmesi yaklaşımlarının etkinliği değerlendirilmiş; model mimarilerinin doğruluk oranı, işlem süresi ve genel başarı düzeyleri karşılaştırmalı olarak analiz edilmiştir.

Karşılaştırmalı analizler sonucunda, her iki veri seti üzerinde en yüksek performansı gösteren model yapılandırmaları belirlenmiştir. Derin öğrenme mimarileri ile geleneksel makine öğrenimi algoritmalarının karşılaştırılması sayesinde, hem doğrudan sınıflandırma hem de öznitelik tabanlı yaklaşımların başarı düzeyleri değerlendirilmiştir. Seçilen nihai model yapılandırması, yapay zekânın diş hekimliğinde tanısal süreçlere entegre edilme potansiyelini açıkça ortaya koymuştur. Elde edilen sonuçlar, eksik diş tespiti ve implant uygunluğu değerlendirmesinde etkili ve güvenilir bir yapay zekâ tabanlı sistem geliştirme yönünde önemli bir katkı sunmaktadır.

2. KAVRAMSAL ÇERÇEVE

Bu çalışma, panoramik diş röntgenleri üzerinden 18 yaş ve üzeri yetişkin bireylerde eksik dişlerin tespiti ve implant uygulanabilirliğinin değerlendirilmesi için entegre bir derin öğrenme modeli geliştirmeyi amaçlamaktadır. 1995-2023 yılları arasında yayınlanan 9 çalışmanın incendiği literatür taramasında, bu iki sürecin birlikte ele alındığı bütünleşik bir modelin eksikliği dikkat çekmektedir. Mevcut çalışmalar genellikle ya sadece eksik diş tespiti ya da implant planlaması üzerine odaklanmıştır. Sadece Park ve diğ. (2022) ile bu çalışma, panoramik radyograflarda eksik dişlerin tespiti ve implant uygunluğunun değerlendirilmesine eşzamanlı olarak odaklanmaktadır. Park ve diğ. (2022) çalışmasında, iki aşamalı bir derin öğrenme yaklaşımı benimsenmiştir: İlk aşamada Mask R-CNN mimarisiyle dişler tek tek segmentlenmiş, ikinci aşamada ise Faster R-CNN ağı ile bu segmentasyon çıktıları analiz edilerek eksik diş bölgeleri tespit edilmiştir. Yani, sistem önce var olan dişleri tanımlamakta, ardından bu bilgilerden yola çıkarak eksik diş boşluklarını belirlemektedir [34].

Buna karşılık, bu tez çalışmasında, farklı CNN mimarileri (DenseNet201, InceptionV3, MobileNetV2, Xception) kullanılarak yalnızca eksik dişlerin tespiti değil, aynı zamanda bu bölgelerin implant yerleştirmeye uygunluk durumları da değerlendirilmiş ve bu sayede altı sınıflı bir sınıflandırma problemi çözülmüştür. Bu çalışmada, hem eksik diş tespiti hem de implant uygulanabilirliği analizini aynı anda gerçekleştirebilen bir yapay zekâ sistemi geliştirilmesi hedeflenmiştir.

Tablo 2.1 ve Tablo 2.2'de verilen çalışmalar, bu araştırmanın metodolojik temelini oluşturmaktadır. Eksik diş tespiti için Ali ve Fujita(2023) ile Mertoğlu ve Keser(2023)'in çalışmalarındaki YOLO ve Faster R-CNN modellerinden esinlenerek yüksek doğruluklu (%99+) bir algoritma geliştirilmesi planlanmaktadır[17,20]. İmplant planlaması aşamasında ise Jader ve Fontineli(2018) ile Rubiu ve diğ. (2023) tarafından geliştirilen segmentasyon yaklaşımları, Akdeniz ve diğ.(1995)'nin analiz yöntemleriyle birleştirilecektir[29,11,32].

Tablo 2.1: İmplant planlama ve diş eksikliği tespiti üzerine yapılan çalışmaların veri seti adı, veriseti türü ve veri sayısı yönünden incelemesi

Referans	Veri Seti Adı	Veri Seti Türü	Veri Sayısı	İlgili Sonuçlar
[11]	Tufts Dental Database	Özel/Klinik	1000 panoramik röntgen	İmplant planlama için anatomik segmentasyon
[17]	Okayama University Hospital Dataset	Özel/Klinik	3.818 panoramik röntgen	Eksik diş tespiti için yüksek doğruluk
[20]	Marmara Üniversitesi Klinik Panorama Radyograf	Özel/Klinik	200 panoramik röntgen	Eksik diş tespitinde yüksek performans
[25]	Belirtilmemiş	Özel/Klinik	108 panoramik röntgen (3.456 diş)	Eksik diş tespitinde en yüksek doğruluk

Tablo 2.1(Devamı)

[29]	Belirtilmemiş	Özel/Açık Erişimli	1.500 panoramik röntgen	Anatomik yapıların segmentasyonu
[30]	Belirtilmemiş	Özel/Klinik	153 hasta görüntüsü	İmplant planlama için anatomik analiz
[32]	Belirtilmemiş	Özel/Klinik	Belirtilmemiş	Panoramiklerin implant planlamada yeterliliği
[33]	UFBA-UESC Dental Image Dataset	Özel/Klinik	Belirtilmemiş	İmplant planlamada anatomik yapıların belirlenmesi
[34]	Belirtilmemiş	Derlenmiş veri seti (386 public + 69 klinik)	455 panoramik röntgen	Eksik diş tespiti; implant uygunluğu dikkate alınmaz

Tablo 2.2: İmplant planlama ve diş eksikliği tespiti üzerine yapılan çalışmaların model ve performans yönünden incelemesi

Referans	**Amaç**	**Model/ Yöntem**	**Performans**
[11]	Diş segmentasyonu	Mask R-CNN	%98.4 doğruluk
[17]	Otomatik diş ve protez tespiti	YOLOv7 (CNN)	Diş: %99.15 mAP, Protez: %97.36 mAP

Tablo 2.2 (Devamı)

[20]	Otomatik diş tespiti	Faster R-CNN	%99.6 duyarlılık
[25]	Eksik diş ve restorasyon tespiti	GoogLeNet	%97.1 doğruluk
[29]	Diş segmentasyonu	Mask R-CNN	%98 doğruluk
[30]	Otomatik diş segmentasyonu	DeepLab-v3 + CNN	Yüksek duyarlılık
[32]	İmplant bölgesi değerlendirme	Radyolojik analiz	Kemik ölçüm hatası <1mm
[33]	Otomatik diş tespiti	Otomatik segmentasyon	Çene ayrımı: 0.99
[34]	Eksik diş ve restorasyon tespiti	Mask R-CNN + Faster R-CNN	Segmentasyon: %92, Tespit: %59

Literatürdeki pek çok yapay zekâ temelli model, eksik diş tespiti ya da implant planlaması gibi tekil görevler üzerine odaklanmış, ancak bu iki süreci entegre eden sistemler sınırlı kalmıştır. Örneğin, Chen ve diğ. (2022) çalışması yüksek doğruluk sağlamış olsa da (GoogLeNet ile %97.1), sadece 108 görüntüden oluşan sınırlı veri seti nedeniyle modelin genellenebilirliği düşüktür [25]. Benzer şekilde, Mertoğlu ve Keser (2023), Faster R-CNN tabanlı modellerle %99.6 duyarlılıkla diş tespiti yapabilmiştir [20]. Ancak bu çalışmalar, implant planlamasına yönelik analizler içermemektedir.

İmplant uygulanabilirliğinin değerlendirilmesi amacıyla yapılan bazı çalışmalarda ise daha çok segmentasyon tabanlı yaklaşımlar tercih edilmiştir. Rubiu ve diğ. (2023),

Mask R-CNN mimarisiyle %98.4 doğruluk oranına ulaşarak diş segmentasyonu yapmış ve implant cerrahisi için kritik anatomik yapıları tanımlamıştır [11]. Bozkurt ve Karagöl (2023) ise mandibula ve maksilla ayrımını otomatikleştirerek panoramik görüntüler üzerinden segmentasyon başarısını %90'ın üzerine çıkarmıştır [33]. Chen ve diğ. (2022), Rubiu ve diğ. (2023) ya da Bozkurt ve Karagöl (2023) gibi çalışmalarda kullanılan modeller, kendi özel amaçları doğrultusunda yüksek performans göstermektedir; ancak eksik diş ve implant analizini bütünleşik şekilde ele alan ve klinik çeşitliliği dikkate alan bir model geliştirilememiştir.

Bu çalışmada, literatürdeki bu boşlukları kapatmak üzere, hem eksik dişlerin tespiti hem de bu bölgelerin implant yerleştirilmeye uygunluğunun analizini gerçekleştiren, altı sınıflı bir yapay zekâ sistemi geliştirilmiştir. Bu doğrultuda, Gerçek Veri Seti ve Hibrit Veri Seti olmak üzere iki büyük veri kümesi kullanılmış; DenseNet201, InceptionV3, MobileNetV2 ve Xception gibi CNN mimarileri ile öznitelik çıkarımı gerçekleştirilmiştir. Elde edilen özellikler daha sonra SVM, KNN, RF ve XGB gibi geleneksel sınıflayıcılarla analiz edilerek modelin genel başarı oranı artırılmıştır. Böylelikle, hem doğruluk oranı yüksek hem de klinik pratikte doğrudan kullanılabilir, kapsamlı bir karar destek sistemi sunulmuştur

Geliştirilecek entegre modelin, diş hekimlerine tanı ve tedavi planlamasında destek sağlayarak klinik süreçleri optimize etmesi beklenmektedir. Çalışmanın nihai hedefi, hem eksik dişlerin doğru tespitini hem de implant uygulaması için gerekli değerlendirmeleri yapabilen bir yapay zeka sistemi sunmaktır.

3. YÖNTEM

3.1. VERİ SETİ

Bu çalışmada, etik kurul izniyle Sağlık Bilimleri Üniversitesi Hamidiye Diş Hekimliği Fakültesi'nden elde edilen 18 yaş üstü bireylere ait panoramik diş röntgeni görüntülerinden oluşturulan veri kümesi "Gerçek Veri Seti" olarak adlandırılmıştır. 540 panoramik diş röntgeni görüntüsünden oluşmaktadır.

Ayrıca, açık kaynaklı panoramik diş röntgeni görüntülerinden oluşmuş Humans in the Loop tarafından sağlanan "Teeth Segmentation Dataset" veri kümesi ile Hexthext tarafından sağlanan "Dental Dataset" veri kümesi birleştirilerek "Hibrit Veri Seti" adında özel veri seti oluşturulmuştur [35, 36]. "Teeth Segmentation on Dental X-ray Images" veri seti 2025 yılında Humans in the Loop tarafından yayımlanmış olup, Demokratik Kongo Cumhuriyeti'nde eğitim almış 12 Humans in the Loop stajyeri tarafından elle segmentasyonu yapılmış 598 panoramik diş röntgeni görüntüsünden oluşmaktadır [2]. [35]. Hexthext tarafından 2023 yılında yayımlanan "Dental Dataset", dental segmentasyon ve benzeri uygulamalar için kullanılan 500 örnek içermektedir [36].

Veri Sınıflandırma

Veri Sınıflandırma aşaması "Gerçek Veri Seti" ve "Hibrit Veri Seti" için aynı yöntemler kullanılarak gerçekleştirilmiştir. Çalışmada kullanılan tüm veri setlerinden yalnızca eksik diş içeren panoramik röntgen görüntüleri seçilmiştir. Seçilen görüntüler, implant uygunluk kriterlerine göre sistematik olarak sınıflandırılmış ve altı farklı kategori altında gruplandırılmıştır:

- **Sadece Alt Çenede Diş Eksikliği**

    1. İmplanta uygun olan vakalar (au) : Alt çenede eksik diş bulunan ancak üst çenede tüm dişlerin mevcut olduğu vakalarda, eksik alt dişlerin tamamı implant için uygunsa Au kategorisine alınmıştır.

2. İmplanta uygun olmayan vakalar (ud): Alt çenede eksik diş bulunan ancak üst çenede tüm dişlerin mevcut olduğu vakalarda, eksik alt dişlerin hiçbiri implant için uygun değilse Ad kategorisine alınmıştır.

- **Sadece Üst Çenede Diş Eksikliği**

3. İmplanta uygun olan vakalar (uu): Üst çenede eksik diş bulunan ancak alt çenede tüm dişlerin mevcut olduğu vakalarda, eksik üst dişlerin tamamı implant için uygunsa Uu kategorisine alınmıştır.

4. İmplanta uygun olmayan vakalar (ud): Üst çenede eksik diş bulunan ancak alt çenede tüm dişlerin mevcut olduğu vakalarda, eksik üst dişlerin hiçbiri implant için uygun değilse Ud kategorisine alınmıştır.

- **Hem Alt Hem Üst Çenede Diş Eksikliği**

5. İmplanta uygun olan vakalar (auu): Hem alt hem üst çenede diş eksikliği bulunan vakalarda, tüm eksik dişler implant için uygunsa Auu kategorisi kullanılmıştır.

6. İmplanta uygun olmayan vakalar (aud): Hem alt hem üst çenede diş eksikliği bulunan vakalarda, hiçbir eksik diş implant için uygun değilse Aud şeklinde etiketlenmiştir.

Bu sınıflandırma sistemi Tablo 3.1'de gösterilmiş ve veri setinin yapılandırılmasında ve sonraki analiz aşamalarında tutarlılık sağlamak amacıyla

oluşturulmuştur. Her bir kategori, ilgili klasör yapısı içerisinde ayrı ayrı saklanarak veri yönetimi kolaylaştırılmıştır.

Sağlık Bilimleri Üniversitesi Hamidiye Diş Hekimliği Fakültesi'nden alınan verilerle oluşturan Gerçek Veri Seti için veri seti sınıflandırılırken kullanılan klasör isimleri ve içerdikleri veri sayıları Tablo 3.1'de gösterilmiştir.

Tablo 3.1: Gerçek Veri Setine ait Sınıflar ve içerdikleri veri sayıları

Sınıf Adı	Eksik Diş Bulunan Çene Türü	İmplanta Uygunluk Durumu	Veri Sayısı
Au	**Alt çene**	Uygun	54
Ad		Uygun değil	16
Uu	**Üst çene**	Uygun	39
Ud		Uygun değil	14
Auu	**Her iki çene**	Uygun	155
Aud		Uygun değil	62

"Teeth Segmentation Dataset" ve "Dental Dataset" veri setleri birleştirilerek oluşturulan Hibrit Veri Seti için veri seti sınıflandırılırken kullanılan klasör isimleri ve içerdikleri veri sayıları Tablo 3.2'de gösterilmiştir.

Tablo 3.2: Hibrit veri setine ait sınıflar ve içerdikleri veri sayıları

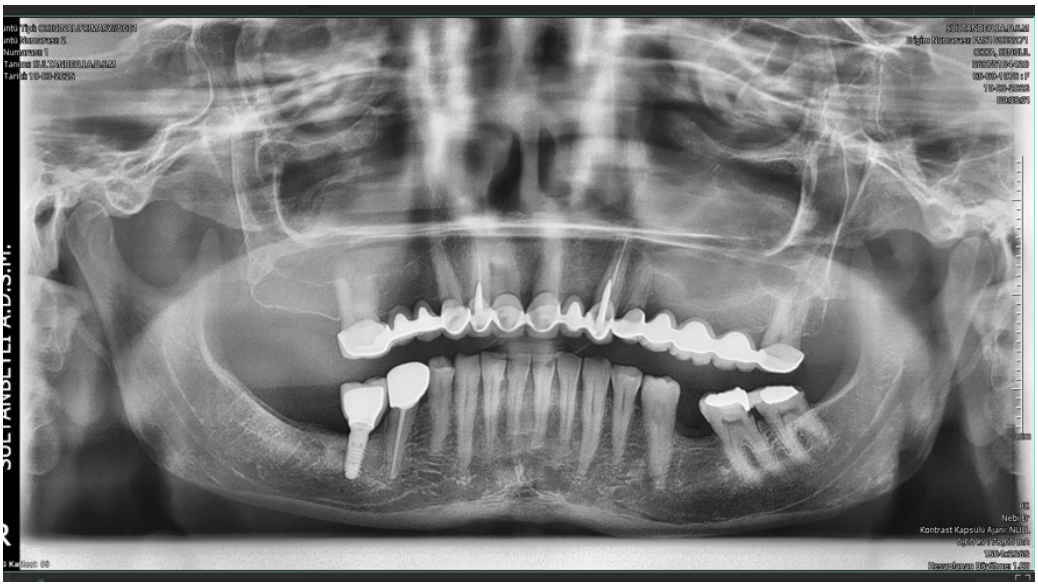
Sınıf Adı	Eksik Diş Bulunan Çene Türü	İmplanta Uygunluk Durumu	Veri Sayısı
Au	**Alt çene**	Uygun	100
Ad		Uygun değil	35
Uu	**Üst çene**	Uygun	12
Ud		Uygun değil	27
Auu	**Her iki çene**	Uygun	47
Aud		Uygun değil	92

Bu çalışmada implant uygunluk kriterleri dental radyografik verilere dayalıdır. Bir diş boşluğuna implant yerleştirilebilmesi için, komşu dişlerin kronları arasındaki mesafenin, herhangi bir komşu dişin genişliğinden büyük olması gereklidir. Ancak, yalnızca taç (kron) düzeyindeki mesafenin yeterli olması, implant için yeterli değildir. Eğer kök seviyesindeki (alveolar krist düzeyi) mesafe, komşu dişlerden herhangi birinin genişliğinden daha küçükse, implant yerleştirme uygun değildir. Ayrıca, bazı özel durumlarda da implant yerleştirilmesi mümkün değildir: üçüncü azı dişi (yirmi yaş dişi) bölgesi, çocuk dişleri, köprü altındaki dişsiz boşluklar, mevcut dişlerin olduğu bölgeler ve diş kökü diş etinin içinde gömülü olan vakalar implant için uygun kabul edilmemiştir. Çekim endikasyonu olan dişler değerlendirmeye dahil edilmemiştir. Alveolar kemik kalınlığı, oklüzal boşluk ve oklüzal ilişkiler de değerlendirme dışında bırakılmıştır. Sinüs

boşluğu ve mandibular kanal gibi anatomik bariyerler de değerlendirme kriteri olarak dahil edilmemiştir. Bu çalışmada implant uygunluğu değerlendirmesi, sadece taç ve kök düzeyindeki boşluğun genişliğinin komşu dişlerden fazla olup olmamasına göre yapılmıştır. Tüm bu kriterler, diş hekimleri tarafından yapılan yönlendirmeler doğrultusunda belirlenmiştir.Veri setindeki örnek görüntüler İkinci rakamdan sonra da nokta olmalı Şekil 3.1, Şekil 3.2, Şekil 3.3, Şekil 3.4, Şekil 3.5, Şekil 3.6, Şekil 3.7, Şekil 3.8, Şekil 3.9, Şekil 3.10, Şekil 3.11 ve şekil 3.12'de verilmiştir.



Şekil 3.1: Gerçek Veri Seti'ne ait örnek veri; alt çenede eksik dişler, implant için uygun(au)



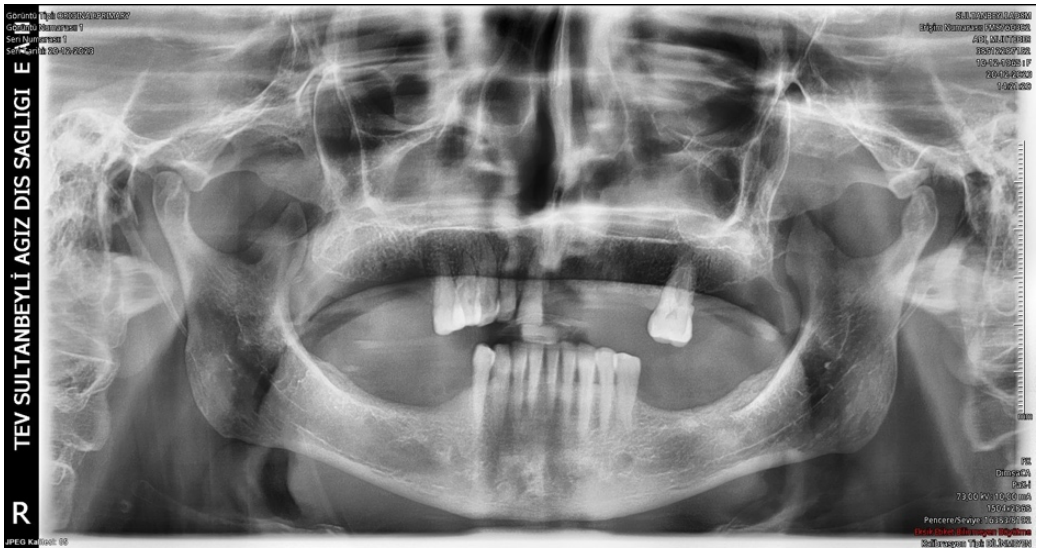
Şekil 3.2: Gerçek Veri Seti'ne ait örnek veri; alt çenede eksik dişler, implant için uygun değil(ad)



Şekil 3.3: Gerçek Veri Seti'ne ait örnek veri; üst çenede eksik dişler, implant için uygun(uu)



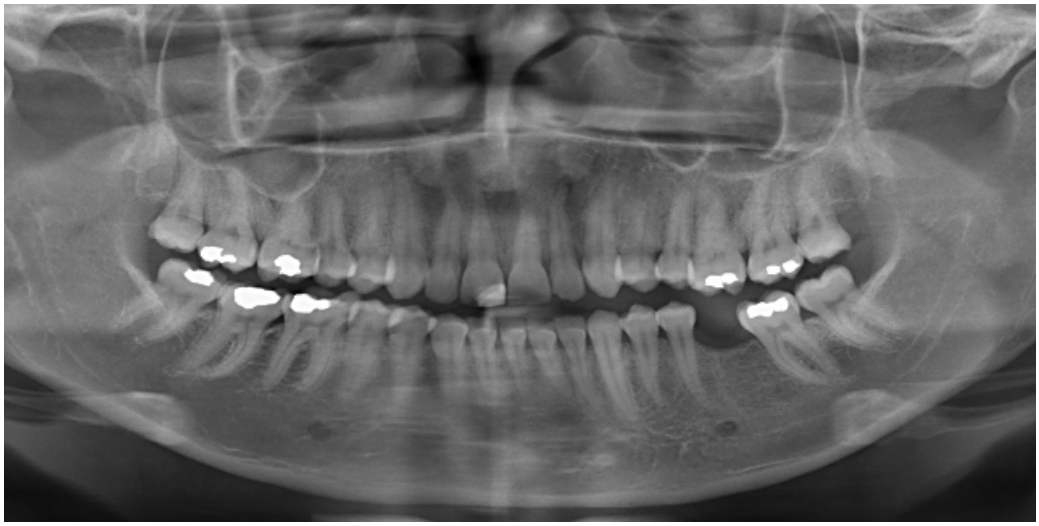
Şekil 3.4: Gerçek Veri Seti için üst çenede eksik dişler, implant için uygun değil(ud)



Şekil 3.5: Gerçek Veri Seti'ne ait örnek veri; her iki çenede eksik dişler, implant için uygun(auu)



Şekil 3.6: Gerçek Veri Seti'ne ait örnek veri; her iki çenede eksik dişler, implant için uygun değil(aud)



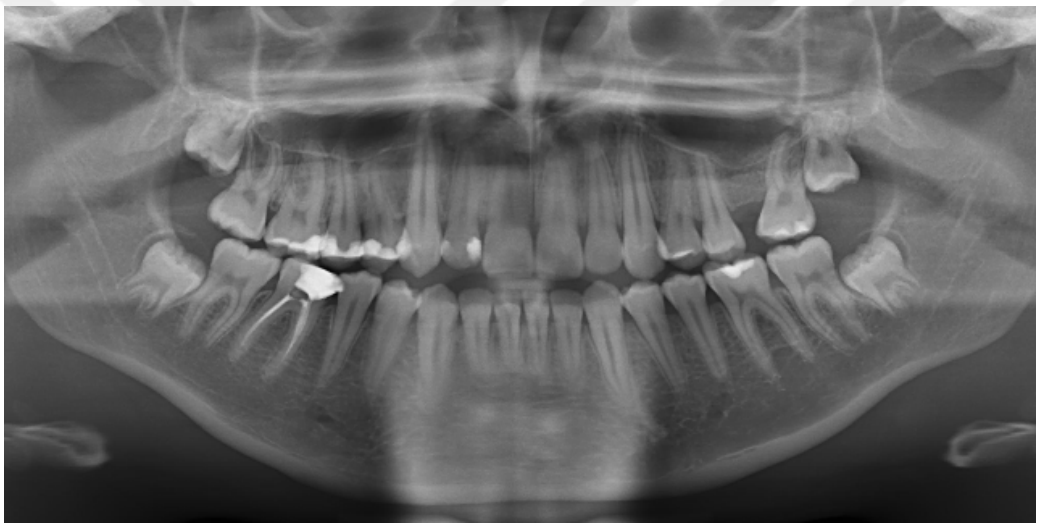
Şekil 3.7: Hibrit Veri Seti'ne ait örnek veri; alt çenede eksik dişler, implant için uygun(au)



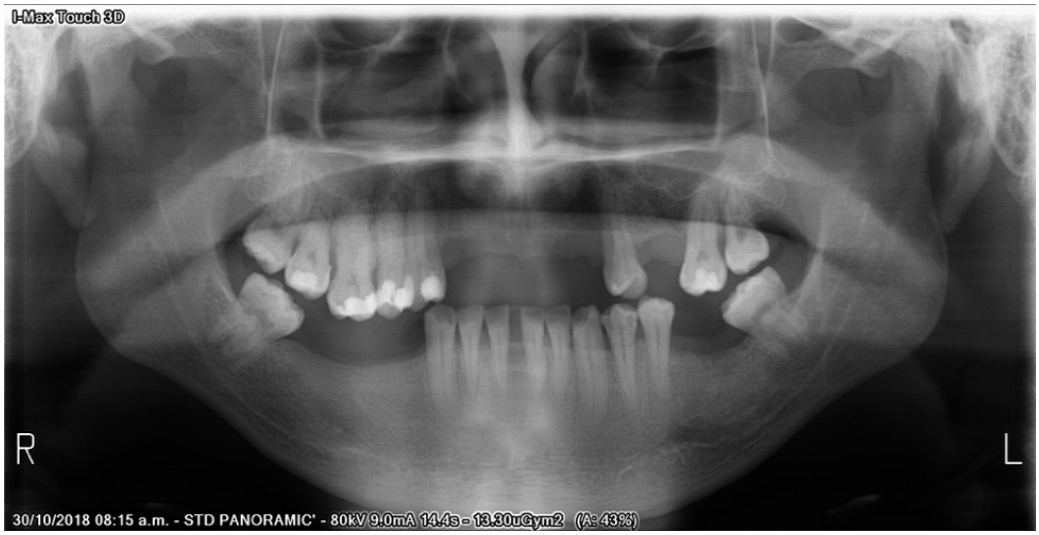
Şekil 3.8: Hibrit Veri Seti'ne ait örnek veri; alt çenede eksik dişler, implant için uygun değil(ad)



Şekil 3.9: Hibrit Veri Seti'ne ait örnek veri; üst çenede eksik dişler, implant için uygun(uu)



Şekil 3.10: Hibrit Veri Seti'ne ait örnek veri; üst çenede eksik dişler, implant için uygun değil(ud)



Şekil 3.11: Hibrit Veri Seti'ne ait örnek veri; her iki çenede eksik dişler, implant için uygun(auu)



Şekil 3.12: Hibrit Veri Seti'ne ait örnek veri; her iki çenede eksik dişler, implant için uygun değil(aud)

3.1. VERİ HAZIRLAMA

Veri Arttırma

Derin öğrenme algoritmalarının genellenebilir ve sağlam sonuçlar elde edebilmesi için büyük ve dengeli veri setlerine ihtiyaç vardır. Ancak, medikal görüntüleme uygulamalarında, özellikle dental radyografide, veri setleri genellikle dengesiz ve küçüktür. Veri artırma (data augmentation), eğitim veri setini etiketleri koruyarak yapay olarak genişletmeye yönelik yaygın bir yaklaşımdır [38]. Rastgele parlaklık ayarlama,

yakınlaştırma ve kırpma gibi teknikler, eğitim örneklerinin sayısını artırmakla kalmaz, aynı zamanda modelin farklı görüntüleme koşullarına uyum sağlama kabiliyetini de artırır [39,40]. Özellikle, parlaklık değişiklikleri dental X-ray'lerdeki aydınlatma tutarsızlıklarını dengelemekte faydalıdır. Yakınlaştırma ve kırpma ise diş görünümlerindeki mekânsal farklılıkların öğrenilmesini sağlar [41]. Birçok çalışma, veri artırmanın sınıflandırma başarımını artırdığını ve aşırı öğrenmeyi azalttığını göstermiştir [42].

Gerçek Veri Seti ve Hibrit Veri Seti içerisinde yer alan diş sınıflarına ait görüntüler başlangıçta sınıflar arası dengesizlik göstermekteydi ve derin öğrenme algoritmalarını eğitmek için yeterli sayıda örnek bulunmamaktaydı. Bu eksiklikleri gidermek ve modelin genellenebilirliğini artırmak amacıyla Gerçek Veri Seti ve Hibrit Veri Seti için veri artırma (data augmentation) tekniklerinden yararlanılmıştır. Bu kapsamda, Keras kütüphanesindeki ImageDataGenerator sınıfı kullanılarak hem Gerçek Veri Seti hem Hibrit Veri Seti içerisindeki görüntüler üzerinde çeşitli dönüşümler uygulanmıştır. Uygulanan işlemler arasında 0.4 radyanlık kaydırma (shearing) dönüşümü ile geometrik çeşitlilik kazandırılmış; parlaklık düzeyleri 0.3 ile 1.8 aralığında rastgele değiştirilerek modelin farklı aydınlatma koşullarında dayanıklılığı artırılmıştır.

Ayrıca, %80 ile %100 arasında rastgele yakınlaştırma işlemi uygulanarak hem genel yapıların hem de ayrıntılı bölgelerin öğrenilmesi desteklenmiştir. Ek olarak, rastgele kırpma işlemleriyle görüntülerin boyut ve şekillerinde değişiklikler yapılarak modelin mekânsal varyasyonlara karşı duyarlılığı artırılmıştır. Bu işlemler sonucunda hem Gerçek Veri Seti hem Hibrit Veri Seti'nin her sınıfı için görüntü sayısı 500'e çıkarılmış; veriler 350 eğitim, 75 doğrulama ve 75 test örneği olacak şekilde dengeli bir yapıda üç alt kümeye ayrılmıştır. Veri artırma sonrası elde edilen örnekler modele sunulmadan önce dikkatli bir şekilde etiketlenmiş ve model eğitimi için hem niteliksel hem de niceliksel olarak zenginleştirilmiş bir veri seti oluşturulmuştur.

Gerçek Veri Seti ve Hibrit Veri Seti'nde yer alan panoramik görüntüler, eksik diş konumlarına göre üç ana kategoriye ayrılmıştır: yalnızca alt dişleri eksik olan bireyler,

yalnızca üst dişleri eksik olan bireyler ve hem alt hem üst dişleri eksik olan bireyler. Her bir kategori, implant tedavisine uygunluk durumuna göre iki alt gruba ayrılmış ve bu alt gruplar, sistematik bir şekilde oluşturulan kısa adlarla tanımlanmıştır. Bu kısa adlandırma sisteminde, harfler eksiklik konumunu ve uygunluk durumunu belirtmektedir. "au" kısaltması "alt çene eksik ve implanta uygun" bireyleri, "ad" ise "alt çene eksik ve implanta uygun değil" bireyleri temsil etmektedir. Benzer şekilde, "uu" üst çene eksik ve implanta uygun, "ud" üst çene eksik ve implanta uygun değil anlamına gelmektedir. Hem alt hem üst çenede diş eksikliği bulunan bireyler için "auu" (implanta uygun) ve "aud" (implanta uygun değil) kısaltmaları kullanılmıştır. Bu kısa adlar, veri organizasyonunun daha sistematik yapılmasını sağlamış ve model eğitimi sürecinde sınıfların ayrıştırılmasını kolaylaştırmıştır. Hem Gerçek Veri Seti ve Hibrit Veri Seti'nde her bir alt grup için başlangıçtaki orijinal veri sayısı farklılık göstermekte olup, sınıflar arası dengesizliği gidermek amacıyla veri artırma (data augmentation) yöntemlerinden faydalanılmıştır. Bu işlemler sonucunda her alt grup için örnek sayısı 500'e tamamlanmış ve böylece derin öğrenme modelinin her sınıfı yeterli temsil eden örneklerle eğitilmesi sağlanmıştır.

Artırılmış veriler, modelin eğitim sürecinde kullanılmak üzere üç alt kümeye ayrılmıştır: eğitim (train), doğrulama (validation) ve test setleri. Her bir alt grupta, 500 görüntüden 350'si eğitim, 75'i doğrulama ve 75'i test amacıyla kullanılmıştır. Böylece, hem modelin öğrenme süreci hem de genel performans değerlendirmesi için dengeli ve sistematik bir veri yapısı oluşturulmuştur. Bu yaklaşım, sınıflar arası örnek sayılarının eşitlenmesi yoluyla modelin aşırı öğrenme eğilimlerinin önüne geçilmesini ve genellenebilirliğin artırılmasını hedeflemektedir.

Artırılmış veri seti, model eğitimi ve değerlendirme için şu şekilde bölünmüştür:

- **Eğitim (Train):** %70 (**350 görüntü/sınıf**),
- **Doğrulama (Validation):** %15 (**75 görüntü/sınıf**),
- **Test:** %15 (**75 görüntü/sınıf**).

Tablo 3.3: Gerçek Veri Seti için klasörlerin kısa adı, içerdikleri veri sayısı, arttırılmış veri vayıları ve eğitim, doğrulama, test içn kullanılan veri sayılarının gösterimi

Sınıflar	İmplanta Uygunluk	Kısa Ad	Veri Sayısı	Arttırılmış Veri Sayısı	Eğitim	Doğrulama	Test
Alt Çenede Dişler Eksik	İmplanta Uygun	au	54	500	350	75	75
	İmplanta Uygun Değil	ad	16	500	350	75	75
Üst Çenede Dişler Eksik	İmplanta Uygun	uu	39	500	350	75	75
	İmplanta Uygun Değil	ud	14	500	350	75	75
Hem Alt Hem Üst Çenede Dişler Eksik	İmplanta Uygun	auu	155	500	350	75	75
	İmplanta Uygun Değil	aud	62	500	350	75	75

Tablo 3.4: Hibrit Veri Seti için klasörlerin kısa adı, içerdikleri veri sayısı, arttırılmış veri vayıları ve eğitim, doğrulama, test içn kullanılan veri sayılarının gösterimi

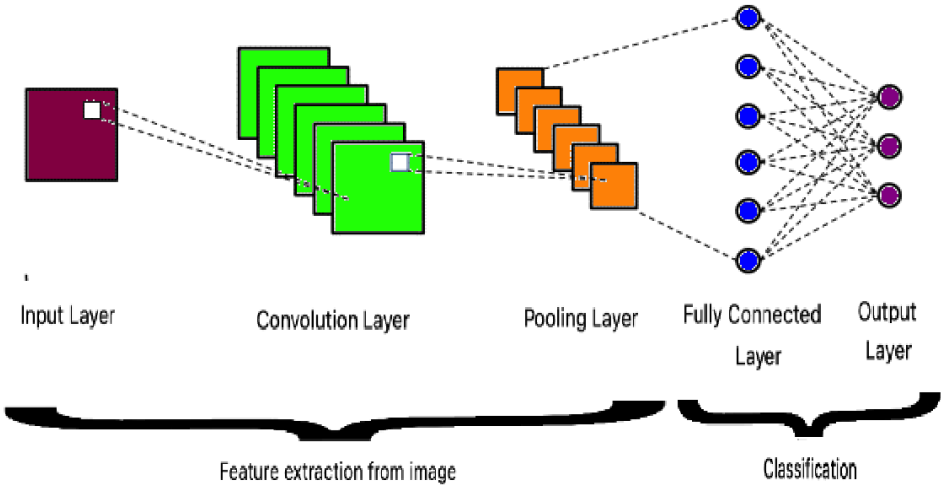
Sınıflar	İmplanta Uygunluk	Kısa Ad	Veri Sayısı	Arttırılmış Veri Sayısı	Eğitim	Doğrulama	Test
Alt Çenede Dişler Eksik	İmplanta Uygun	au	93	500	350	75	75
	İmplanta Uygun Değil	ad	35	500	350	75	75

Tablo 3.4(Devamı)

Üst Çenede Dişler Eksik	İmplanta Uygun	uu	12	500	350	75	75
	İmplanta Uygun Değil	ud	27	500	350	75	75
Hem Alt Hem Üst Çenede Dişler Eksik	İmplanta Uygun	auu	47	500	350	75	75
	İmplanta Uygun Değil	aud	92	500	350	75	75

3.2. KULLANILAN MODELLER

Bu çalışmada, dental panoramik röntgen görüntülerinin sınıflandırılmasında derin öğrenme tabanlı **Convolutional Neural Network (CNN)** mimarisi kullanılmıştır. CNN'ler, görüntü verilerindeki mekânsal hiyerarşiyi ve yerel özellikleri öğrenmek üzere tasarlanmış çok katmanlı yapay sinir ağlarıdır. **Konvolüsyon katmanları**, küçük filtreler (kernel) aracılığıyla görüntüdeki kenar, çizgi ve renk geçişleri gibi temel özellikleri yakalayarak anlamlı özellik haritaları üretir [11,16,18]. **Havuzlama (pooling) katmanları** ise genellikle maksimum (max pooling) veya ortalama (average pooling) değer seçerek özellik haritalarının boyutunu küçültür, böylece hesaplama yükünü azaltır ve aşırı öğrenmeyi önler [12,23,24]. Bu yapılar, yüksek boyutlu ve karmaşık medikal görüntülerin otomatik analizi için ideal bir mimari sağlar. Genel CNN(Evrişimli Sinir Ağı) mimarisi Şekil 3.13'de gösterilmiştir.



Şekil 3.13: Genel CNN mimarisi

Bu çalışmada, panoramik radyograflarda eksik dişlerin tespitine yönelik olarak CNN tabanlı derin öğrenme modellerinden DenseNet201, InceptionV3, MobileNetV2 ve Xception ile geleneksel makine öğrenimi sınıflandırıcıları olan **Support Vector Machines (SVM)**, **K-Nearest Neighbors (KNN)**, **Random Forest (RF)** ve XGBoost (XGB) kullanılmıştır. Evrişimli sinir ağı (CNN) mimarileri, görüntü verilerini işleme, örüntüleri tanıma, karmaşık ilişkileri öğrenme ve yüksek doğrulukta sınıflandırma yapabilme yetenekleri sayesinde, eksik dişlerin doğru ve güvenilir bir şekilde tespitinde etkili bir yöntem olarak öne çıkmaktadır.

CNN Mimarileri

Çalışmada performans karşılaştırması için dört farklı CNN mimarisi uygulanmıştır: **DenseNet201, InceptionV3, MobileNetV2** ve **Xception**.

DenseNet201, her katmanın kendisinden önce gelen tüm katmanlardan girdi almasını sağlayan yoğun bağlantı yapısıyla karakterize edilir. Bu yapı, özellik yayılımını artırır, gradyan kaybı sorununu azaltır ve parametre verimliliğini geliştirir [43].

InceptionV3, aynı seviyede farklı filtre boyutlarıyla paralel konvolüsyon işlemleri gerçekleştirerek hem ince ayrıntılı hem de soyut özellikleri eşzamanlı çıkarır. Bu yapı, karmaşık ve yüksek çözünürlüklü görsel verilerde özellikle etkilidir [44].

MobileNetV2, tersine kalıntı (inverted residual) yapısı ve doğrusal darboğazlarla donatılmıştır; böylece sınıflandırma doğruluğu ve hesaplama verimliliği arasında dengeli bir yapı sunar [45].

Xception geleneksel Inception modülleri yerine derin ayrılabilir konvolüsyonlar kullanarak model parametrelerinin daha verimli kullanılmasını sağlar. Mekânsal ve kanal bazlı hesaplamaları ayırarak daha derin ve güçlü temsiller üretir; bu sayede büyük veri setlerinde dahi InceptionV3'ten üstün performans gösterir [46].

Bu dört CNN mimarisinin karşılaştırmalı performans analizi, dental panoramik röntgen görüntülerinin otomatik sınıflandırılmasında en uygun modelin belirlenmesi amacıyla gerçekleştirilmiştir.

Makine Öğrenimi Modelleri

Bu çalışmada kullanılan makine öğrenimi algoritmaları şunlardır:

Destek Vektör Makineleri (SVM): Farklı sınıfları en iyi şekilde ayıran hiper düzlemi bulmayı hedefler. Yüksek boyutlu veri kümelerinde etkili ve dayanıklı bir sınıflandırma yöntemidir [47].

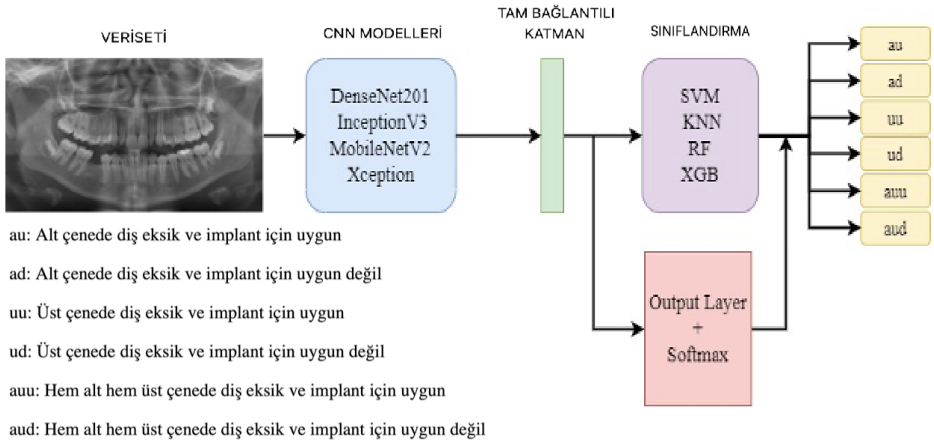
En Yakın Komşu (KNN): Yeni örnekleri, öz nitelik uzayında en yakın komşularının sınıfına göre sınıflandırır. Sezgisel ve parametrik olmayan bir yöntemdir ancak büyük veri kümelerinde performansı düşebilir [48].

Random Forest (RF): Birden fazla karar ağacı oluşturarak topluluk öğrenmesine dayanır. Gürültüye ve aşırı öğrenmeye karşı dayanıklıdır [49].

XGBoost (XGB): Gradyan artırmalı karar ağaçlarının hızlı ve verimli bir uygulamasıdır. Düzenleme teknikleri ve optimize hesaplama sayesinde güçlü performans sunar [50].

3.3. MODEL TASARIMI

Bu çalışmada, eksik dişlerin implant uygulanabilirliğini belirlemek amacıyla iki analiz gerçekleştirilmiştir. İlk analizde, DenseNet201, InceptionV3, MobileNetV2 ve Xception gibi derin öğrenme modelleri kullanılmıştır. İkinci analizde ise, eksik dişlerin implant uygunluğunu belirleme başarısını artırmak için iki aşamalı bir yöntem önerilmiştir. İlk aşamada, CNN modelleri öznitelik çıkarıcı olarak kullanılmıştır. Girdi verisi her CNN modeli için ayrı ayrı kullanılmış ve sınıflandırma katmanından önce öznitelikler CNN tarafından çıkarılmıştır. İkinci aşamada ise, elde edilen öznitelikler kullanılarak SVM, KNN, RF ve XGB sınıflandırıcıları uygulanmıştır. Çalışmada kullanılan modellerin sınıflandırma performansları ölçülmüştür. Çalışmada kullanılan sistemin genel tasarımı Şekil 3.14'de gösterilmektedir.



Şekil 3.14: Önerilen çalışmanın genel tasarımı

Bu çalışmada kullanılan CNN modelleri ve sınıflandırıcıların parametre değerleri Tablo 3.5'de gösterilmiştir.

Tablo 3.5: CNN modelleri ve ML sınıflandırıcılarının parametre değerleri

Models	Parameters	Value
DenseNet201	image size	150 x 150
InceptionV3	learning rate	0.001
MobileNetV2	batch size	16
Xception	epoch	100
	optimization	nadam
RF	n_estimators	50
	random_state	42
	criterion	gini
	min_samples_split	2
	min_samples_leaf	1
	max_features	sqrt
	bootstrap	true
XGB	booster	gbtree
	learning_rate	0.1
	n_estimators	100
SVM	c	1
	kernel	rbf
	degree3	3
	decision_function_shape	ovr
KNN	n_neighbors	1
	p	2
	metric	minkowski
	leaf_size	30

4. BULGULAR

Çalışmada eksik dişlerin implant için uygunluğunu belirlemek amacıyla iki analiz gerçekleştirilmiştir. İlk analizde, DenseNet201, InceptionV3, MobileNetV2 ve Xception

derin öğrenme modelleri kullanılmıştır. İkinci analizde ise, CNN modelleri özellik çıkarıcı olarak kullanılmış; elde edilen özellikler ile SVM, KNN, RF ve XGB sınıflandırıcıları oluşturulmuştur. Bu yaklaşım ile, her CNN mimarisinin kendi içinde ve diğer sınıflandırıcılarla olan etkileşimleri analiz edilmiş, sınıflar arası doğruluk, duyarlılık, özgüllük ve F1 skoru gibi ölçütlerle kıyaslanabilir bir performans değerlendirme yapısı oluşturulmuştur. Söz konusu analizler, iki farklı veri seti üzerinde ayrı ayrı gerçekleştirilmiştir: Gerçek Veri Seti, İstanbul Sağlık Bilimleri Üniversitesi Hamidiye Diş Hekimliği Fakültesi'nden elde edilen gerçek klinik görüntülerden; Hibrit Veri Seti ise "Teeth Segmentation Dataset" ve "Dental Dataset" adlı iki açık erişimli kaynağın birleştirilmesiyle oluşturulmuştur[35,36]. Bulgular, her bir kombinasyon için ayrı başlıklar altında detaylandırılmıştır.

4.1. PERFORMANS METRİKKLERİ

Çalışmada kullanılan modellerin performansını değerlendirmek için karışıklık matrisi (confusion matrix) kullanılmıştır. Performans ölçütü olarak doğruluk (accuracy), duyarlılık (recall), kesinlik (precision) ve F1-skora (F1-score) yer verilmiştir. Performans metriklerinin hesaplanmasında, yanlış negatif (False Negative - FN), yanlış pozitif (False Positive - FP), doğru negatif (True Negative - TN) ve doğru pozitif (True Positive - TP) değerleri kullanılmıştır.

Aşağıda bu metriklerin hesaplanma formülleri yer almaktadır:

$$\textbf{Doğruluk (Accuracy)} = (TP + TN) / (TP + TN + FP + FN) \quad (1)$$

$$\textbf{Duyarlılık (Recall)} = TP / (TP + FN) \quad (2)$$

$$\textbf{Kesinlik (Precision)} = TP / (TP + FP) \quad (3)$$

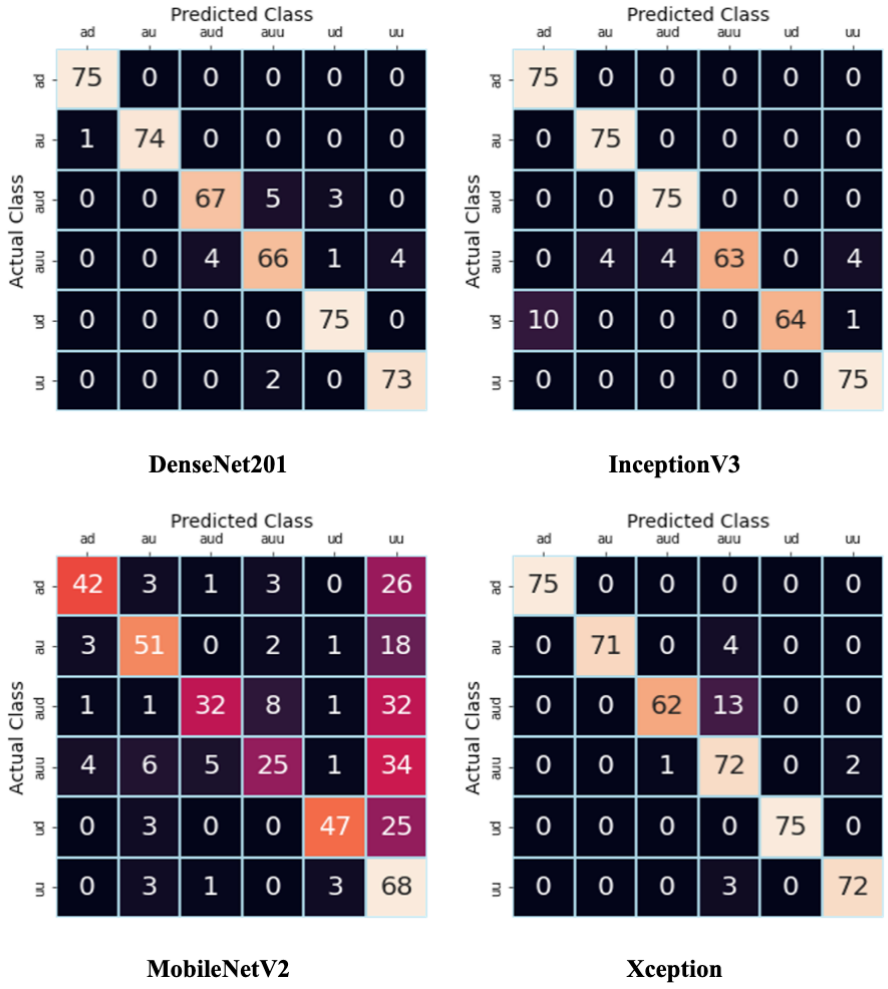
$$\textbf{F1 Skoru (F1-score)} = 2 \times (\text{Recall} \times \text{Precision}) / (\text{Recall} + \text{Precision}) \quad (4)$$

4.2. CNN MODELLERİNİN ANALİZ SONUÇLARI

Gerçek Veri Seti İçin CNN Modellerinin Analiz Sonuçları

İlk analizde, Gerçek Veri Seti ve Hibrit Veri Seti için CNN modellerinin başarı oranları karşılaştırılarak performansları incelenmiştir. Dört farklı CNN modeli eğitilmiştir. Modellerin sınıflandırma işlemlerinde **softmax** fonksiyonu kullanılmıştır.

Gerçek Veri Seti için CNN modellerine ait karmaşıklık (confusion) matrisleri Şekil 4.1'de gösterilmiştir.



Şekil 4.1: Gerçek Veri Seti için CNN modellerinin karışıklık(confusion) matrisleri

Oluşturulan veri kümesi üzerinde eğitilen dört farklı CNN modelinin performansları Tablo 4.1.de gösterilmiştir.

Tablo 4.1: Gerçek Veri Seti için CNN modellerinin karışıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	98.68	100.00	99.34	%95
	au	100.00	98.67	99.33	
	aud	94.37	89.33	91.78	
	auu	90.41	88.00	89.19	
	ud	94.94	100.00	97.40	
	uu	94.81	97.33	96.05	
InceptionV3	ad	88.24	100.00	93.75	%94
	au	94.94	100.00	97.40	
	aud	94.94	100.00	97.40	
	auu	100.00	84.00	91.30	
	ud	100.00	85.33	92.09	
	uu	93.75	100.00	96.77	
MobileNetV2	ad	84.00	56.00	67.20	%58
	au	76.12	68.00	71.83	
	aud	82.05	42.67	56.14	
	auu	65.79	33.33	44.25	
	ud	88.68	62.67	73.44	
	uu	33.50	90.67	48.92	

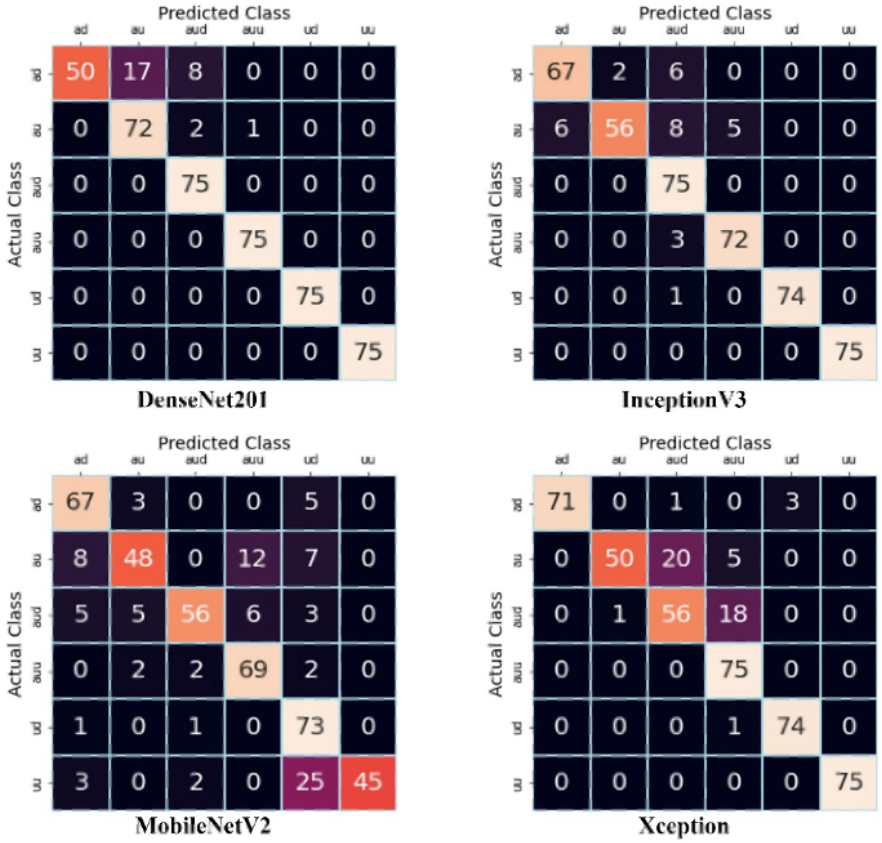
Tablo 4.1.(Devamı)

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
Xception	ad	100.00	100.00	100.00	%94
	au	100.00	94.67	97.26	
	aud	98.41	82.67	89.86	
	auu	78.26	96.00	86.23	
	ud	100.00	100.00	100.00	
	uu	97.30	96.00	96.64	

Gerçek Veri Seti için Tablo 4.1.de sunulan sonuçlar incelendiğinde DenseNet201, InceptionV3, MobileNetV2 ve Xception'ın sırasıyla %95, %94, %58 ve %94 genel doğruluk performansları gösterdiği görülmüştür. DenseNet201 modeli CNN modelleri arasında en iyi performansı göstermiştir.

Hibrit Veri Seti İçin CNN Modellerinin Analiz Sonuçları

Hibrit Veri Seti için CNN modellerine ait karmaşıklık (confusion) matrisleri Şekil 4.2'de gösterilmiştir.



Şekil 4.2: Hibrit Veri Seti için CNN modellerinin karışıklık(confusion) matrisleri

Oluşturulan veri kümesi üzerinde eğitilen dört farklı CNN modelinin performansları Tablo 4.2'de gösterilmiştir.

Tablo 4.2: Hibrit Veri Seti için CNN modellerinin karışıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	1.00	0.67	0.80	%94
	au	0.81	0.96	0.88	
	aud	0.88	1.00	0.94	
	auu	0.99	1.00	0.99	
	ud	1.00	1.00	1.00	
	uu	1.00	1.00	1.00	
InceptionV3	ad	0.92	0.89	0.91	%93
	au	0.97	0.75	0.84	
	aud	0.81	1.00	0.89	
	auu	0.94	0.96	0.95	
	ud	1.00	0.99	0.99	
	uu	1.00	1.00	1.00	
MobileNetV2	ad	0.80	0.89	0.84	%80
	au	0.83	0.64	0.72	
	aud	0.92	0.75	0.82	
	auu	0.79	0.92	0.85	
	ud	0.63	0.97	0.77	
	uu	1.00	0.60	0.75	

Tablo 4.2(Devamı)

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
Xception	ad	1.00	0.95	0.97	%89
	au	0.98	0.67	0.79	
	aud	0.73	0.75	0.74	
	auu	0.76	1.00	0.86	
	ud	0.96	0.99	0.97	
	uu	1.00	1.00	1.00	

Hibrit Veri Seti için Tablo 4.2'de sunulan sonuçlar incelendiğinde DenseNet201, InceptionV3, MobileNetV2 ve Xception'ın sırasıyla %94, %93, %80 ve %89 genel doğruluk performansları gösterdiği görülmüştür. DenseNet201 modeli CNN modelleri arasında en iyi performansı göstermiştir.

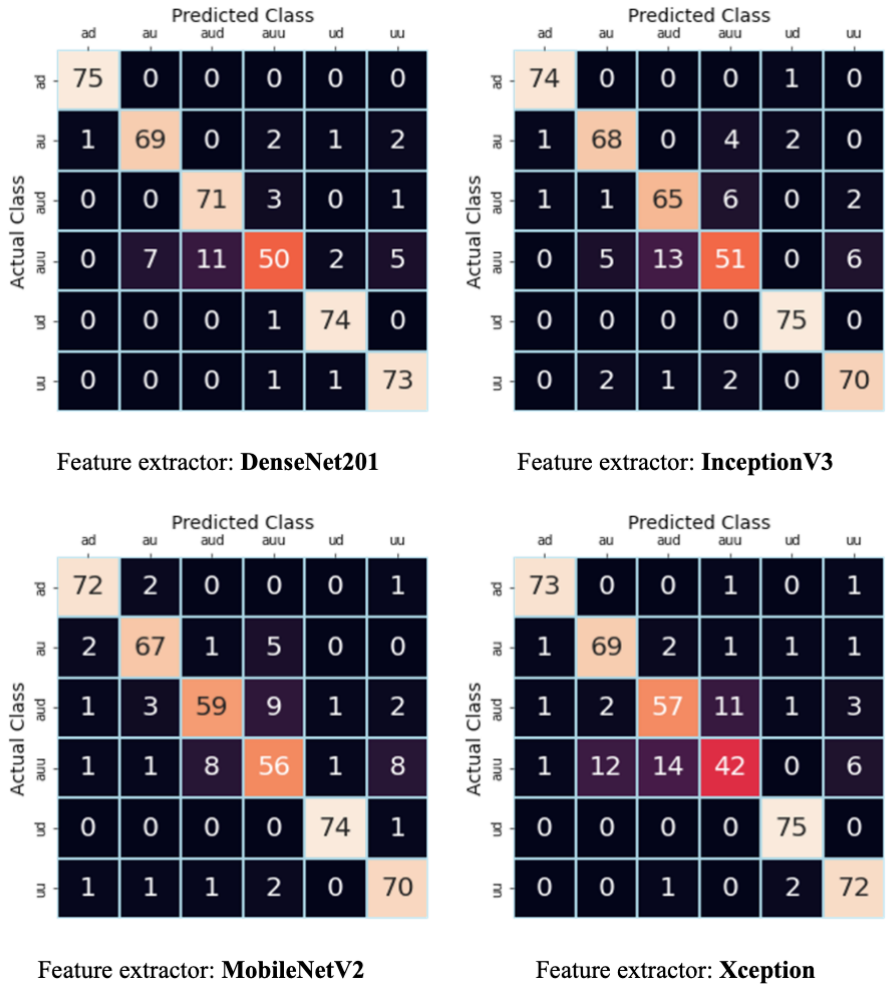
4.3. MAKİNE ÖĞRENİMİ SINIFLANDIRICILARININ ANALİZ SONUÇLARI

İkinci analizde, Gerçek Veri Seti ve Hibrit Veri Seti için CNN modelleri ve sınıflandırıcıların başarı oranları karşılaştırılarak performansları incelenmiştir. Bu analizde, CNN modelleri özellik çıkarıcı olarak kullanılmıştır. Elde edilen özellikler her iki veri seti için SVM, KNN, RF ve XGB sınıflandırıcıları ile sınıflandırılmıştır.

SVM Sınıflandırıcısının Analiz Sonuçları

4.3.1.1. Gerçek Veri Seti İçin SVM Sınıflandırıcısının Analiz Sonuçları

Gerçek Veri Seti için SVM sınıflandırıcısına ait karmaşıklık(confusion) matrisleri Şekil 4.3'de gösterilmiştir.



Feature extractor: **DenseNet201** Feature extractor: **InceptionV3**

Feature extractor: **MobileNetV2** Feature extractor: **Xception**

Şekil 4.3: Gerçek Veri Seti için SVM sınıflandırıcısının karışıklık(confusion) matrisleri

Gerçek Veri Seti üzerinde eğitilmiş dört farklı CNN Feature Extractor ile XGB sınıflayıcısının performansları Tablo 4.3'de gösterilmiştir.

Tablo 4.3: Gerçek Veri Seti için SVM sınıflandırıcısının karmaşıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	98.68	100.00	99.34	%91
	au	90.79	92.00	91.39	
	aud	86.59	94.67	90.45	
	auu	87.72	66.67	75.76	
	ud	94.87	98.67	96.73	
	uu	90.12	97.33	93.59	
InceptionV3	ad	97.37	98.67	98.01	%89
	au	89.47	90.67	90.07	
	aud	82.28	86.67	84.42	
	auu	80.95	68.00	73.91	
	ud	96.15	100.00	98.04	
	uu	89.74	93.33	91.50	
MobileNetV2	ad	93.51	96.00	94.74	%88
	au	90.54	89.33	89.93	
	aud	85.51	78.67	81.94	
	auu	77.78	74.67	76.19	
	ud	97.37	98.67	98.01	
	uu	85.37	93.33	89.17	

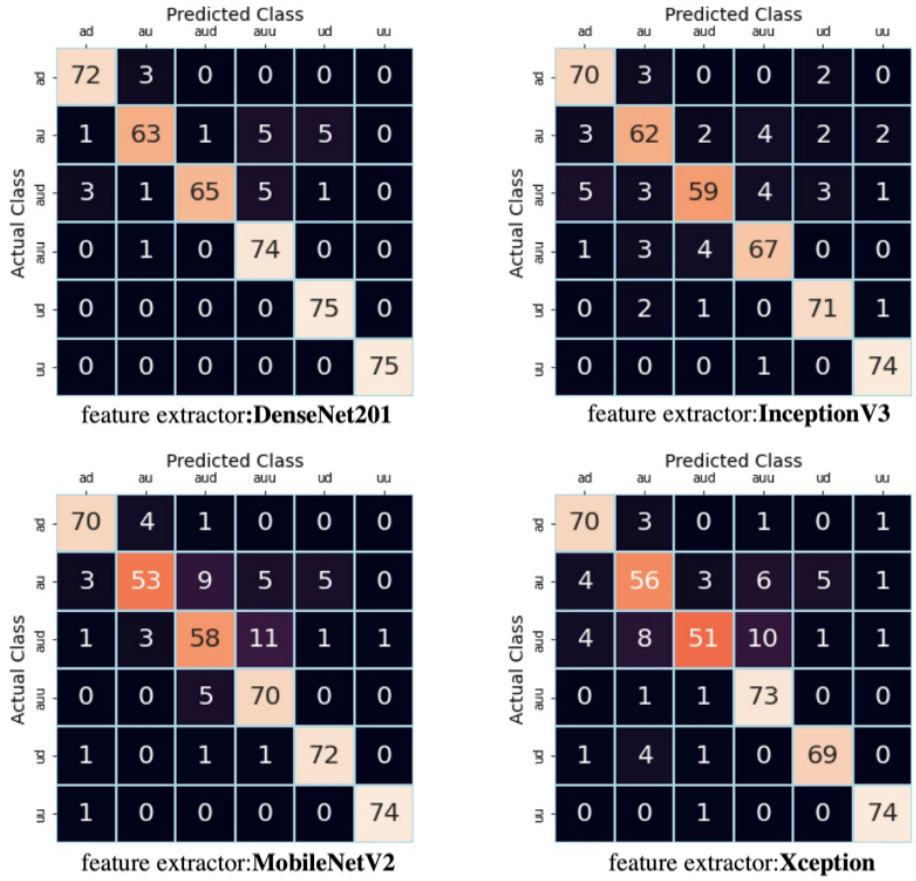
Tablo 4.3(Devamı)

Xception	ad	96.05	97.33	96.69	%86
	au	83.13	92.00	87.34	
	aud	77.03	76.00	76.51	
	auu	76.36	56.00	64.62	
	ud	94.94	100.00	97.40	
	uu	86.75	96.00	91.14	

Gerçek Veri Seti için Tablo 4.3'de sunulan sonuçlar incelendiğinde, feature extraction için DenseNet201, InceptionV3, MobileNetV2 ve Xception modellerini kullanan SVM sınıflandırıcısının sırasıyla %91, %89, %88 ve %86 genel doğruluk performansı gösterdiği görülmektedir. Özellik çıkarıcı olarak SVM sınıflandırıcı modeliyle DenseNet201 en iyi performansı göstermiştir.

4.3.1.2. Hibrit Veri Seti İçin SVM Sınıflandırıcısının Analiz Sonuçları

Hibrit Veri Seti için SVM sınıflandırıcısına ait karmaşıklık(confusion) matrisleri Şekil 4.4'de gösterilmiştir.



Şekil 4.4: Hibrit Veri Seti için SVM sınıflandırıcısının karışıklık(confusion) matrisleri

Hibrit Veri Seti üzerinde eğitilmiş dört farklı CNN Feature Extractor ile XGB sınıflayıcısının performansları Tablo 4.4'de gösterilmiştir.

Tablo 4.4: Hibrit Veri Seti için SVM sınıflandırıcısının karmaşıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	0.95	0.96	0.95	%94
	au	0.93	0.84	0.88	
	aud	0.98	0.87	0.92	
	auu	0.88	0.99	0.93	
	ud	0.93	1.00	0.96	
	uu	1.00	1.00	1.00	
InceptionV3	ad	0.89	0.93	0.91	%90
	au	0.85	0.83	0.84	
	aud	0.89	0.79	0.84	
	auu	0.88	0.89	0.89	
	ud	0.91	0.95	0.93	
	uu	0.95	0.99	0.97	
MobileNetV2	ad	0.92	0.93	0.93	%88
	au	0.88	0.71	0.79	
	aud	0.78	0.77	0.78	
	auu	0.80	0.93	0.86	
	ud	0.92	0.96	0.94	
	uu	0.99	0.99	0.99	

Tablo 4.4(Devamı)

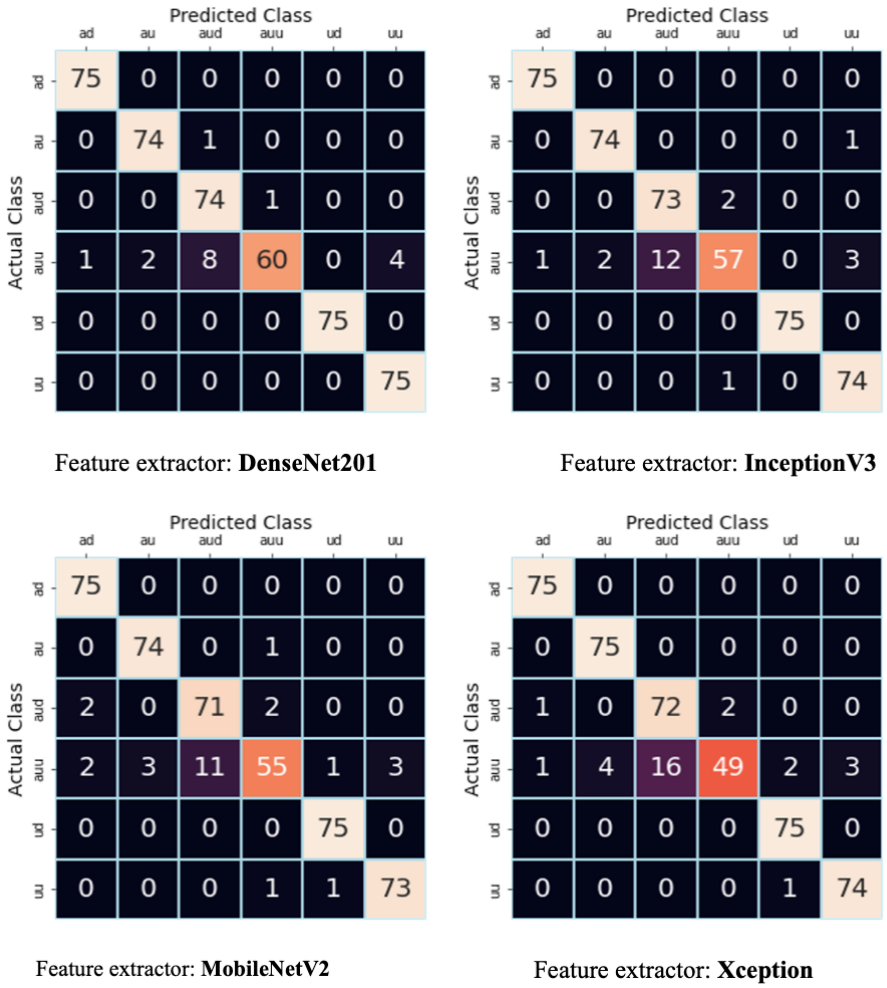
Xception	ad	0.89	0.93	0.91	%87
	au	0.78	0.75	0.76	
	aud	0.89	0.68	0.77	
	auu	0.81	0.97	0.88	
	ud	0.92	0.92	0.92	
	uu	0.96	0.99	0.97	

Hibrit Veri Seti için Tablo 4.4'de sunulan sonuçlar incelendiğinde, feature extraction için DenseNet201, InceptionV3, MobileNetV2 ve Xception modellerini kullanan SVM sınıflandırıcısının sırasıyla %94, %90, %88 ve %87 genel doğruluk performansı gösterdiği görülmektedir. Özellik çıkarıcı olarak SVM sınıflandırıcı modeliyle DenseNet201 en iyi performansı göstermiştir.

KNN Sınıflandırıcısının Analiz Sonuçları

4.3.1.3. Gerçek Veri Seti için KNN Sınıflandırıcısının Analiz Sonuçları

Gerçek Veri Seti için KNN sınıflandırıcısına ait karmaşıklık(confusion) matrisleri Şekil 4.5'de gösterilmiştir.



Feature extractor: **DenseNet201**

Feature extractor: **InceptionV3**

Feature extractor: **MobileNetV2**

Feature extractor: **Xception**

Şekil 4.5: Gerçek Veri Seti için KNN sınıflandırıcısının karışıklık(confusion) matrisleri

Gerçek Veri Seti üzerinde eğitilmiş dört farklı CNN Feature Extractor ile XGB sınıflayıcısının performansları Tablo 4.5'de gösterilmiştir.

Tablo 4.5: Gerçek Veri Seti için KNN sınıflandırıcısının karmaşıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	98.68	100.00	99.34	%96
	au	97.37	98.67	98.01	
	aud	89.16	98.67	93.67	
	auu	98.36	80.00	88.24	
	ud	100.00	100.00	100.00	
	uu	94.94	100.00	97.40	
InceptionV3	ad	98.68	100.00	99.34	%95
	au	97.37	98.67	98.01	
	aud	85.88	97.33	91.25	
	auu	95.00	76.00	84.44	
	ud	100.00	100.00	100.00	
	uu	94.87	98.67	96.73	
MobileNetV2	ad	94.94	100.00	97.40	%94
	au	96.10	98.67	97.37	
	aud	86.59	94.67	90.45	
	auu	93.22	73.33	82.09	
	ud	97.40	100.00	98.68	
	uu	96.05	97.33	96.69	

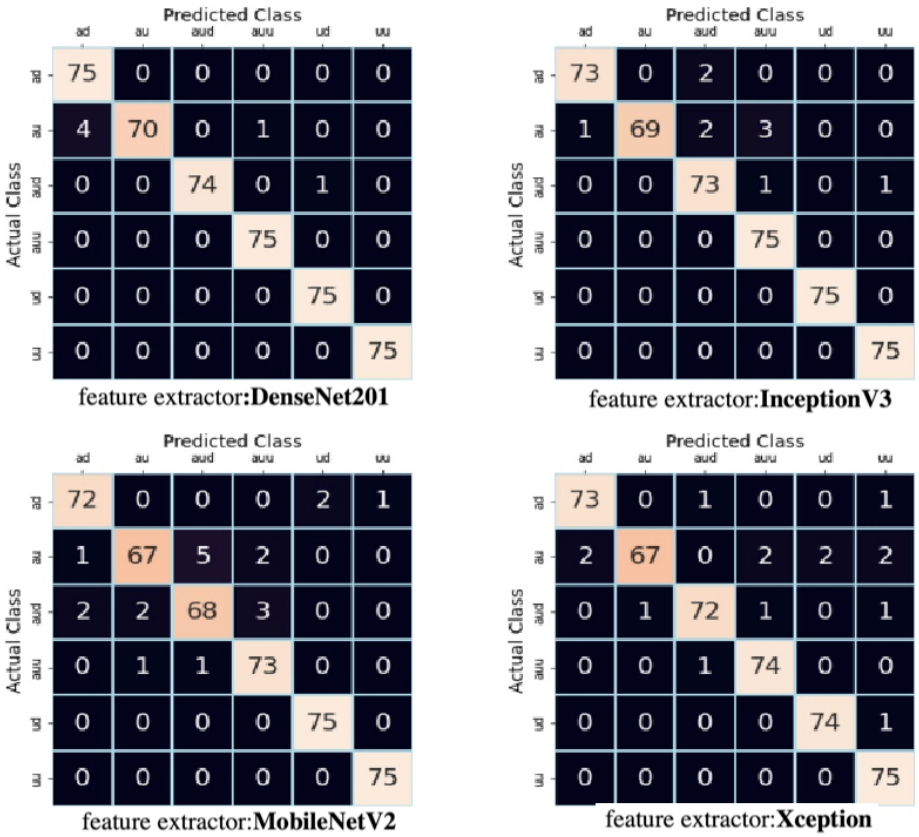
Tablo 4.5(Devamı)

Xception	ad	97.40	100.00	98.68	%93
	au	94.94	100.00	97.40	
	aud	81.82	96.00	88.34	
	auu	96.08	65.33	77.78	
	ud	96.15	100.00	98.04	
	uu	96.10	98.67	97.37	

Gerçek Veri Seti için Tablo 4.5'de sunulan sonuçlar incelendiğinde, feature extraction için DenseNet201, InceptionV3, MobileNetV2 ve Xception modellerini kullanan KNN sınıflandırıcısının sırasıyla %96, %95, %94 ve %93 genel doğruluk(accuracy) performansı gösterdiği görülmektedir. Özellik çıkarıcı olarak KNN sınıflandırıcı modeliyle DenseNet201 en iyi performansı göstermiştir.

4.3.1.4. Hibrit Veri Seti için KNN Sınıflandırıcısının Analiz Sonuçları

Hibrit Veri Seti için KNN sınıflandırıcısına ait karmaşıklık(confusion) matrisleri Şekil 4.6'da gösterilmiştir.



Şekil 4.6: Hibrit Veri Seti için KNN sınıflandırıcısının karışıklık(confusion) matrisleri

Hibrit Veri Seti üzerinde eğitilmiş dört farklı CNN Feature Extractor ile XGB sınıflayıcısının performansları Tablo 4.6'da gösterilmiştir.

Tablo 4.6: Hibrit Veri Seti için KNN sınıflandırıcısının karmaşıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	0.95	1.00	0.97	%99
	au	1.00	0.93	0.97	
	aud	1.00	0.99	0.99	
	auu	0.99	1.00	0.99	
	ud	0.99	1.00	0.99	
	uu	1.00	1.00	1.00	
InceptionV3	ad	0.99	0.97	0.98	%98
	au	1.00	0.92	0.96	
	aud	0.95	0.97	0.96	
	auu	0.95	1.00	0.97	
	ud	1.00	1.00	1.00	
	uu	0.99	1.00	0.99	
MobileNetV2	ad	0.96	0.96	0.96	%96
	au	0.96	0.89	0.92	
	aud	0.92	0.91	0.91	
	auu	0.94	0.97	0.95	
	ud	0.97	1.00	0.99	
	uu	0.99	1.00	0.99	

Tablo 4.6(Devamı)

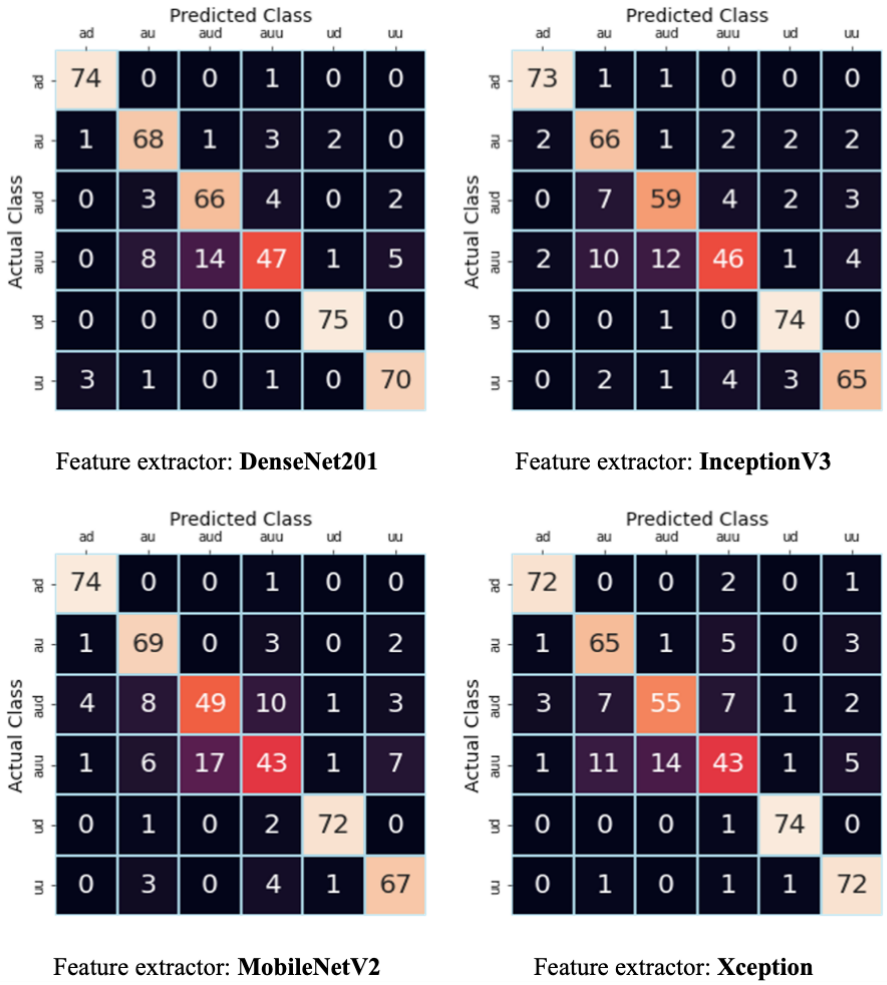
Xception	ad	0.97	0.97	0.97	%97
	au	0.99	0.89	0.94	
	aud	0.97	0.96	0.97	
	auu	0.96	0.99	0.97	
	ud	0.97	0.99	0.98	

Hibrit Veri Seti için Tablo 4.6'da sunulan sonuçlar incelendiğinde, feature extraction için DenseNet201, InceptionV3, MobileNetV2 ve Xception modellerini kullanan KNN sınıflandırıcısının sırasıyla %99, %98, %96 ve %97 genel doğruluk(accuracy) performansı gösterdiği görülmektedir. Özellik çıkarıcı olarak KNN sınıflandırıcı modeliyle DenseNet201 en iyi performansı göstermiştir.

RF Sınıflandırıcısının Analiz Sonuçları

4.3.1.5. Gerçek Veri Seti İçin RF Sınıflandırıcısının Analiz Sonuçları

Gerçek Veri Seti için RF sınıflayıcısına ait karmaşıklık (confusion) matrisleri Şekil 4.7'de gösterilmiştir.



Feature extractor: **DenseNet201** Feature extractor: **InceptionV3**

Feature extractor: **MobileNetV2** Feature extractor: **Xception**

Şekil 4.7: Gerçek Veri Seti için RF sınıflandırıcısının karışıklık(confusion) matrisleri

Gerçek Veri Seti üzerinde eğitilmiş dört farklı CNN Feature Extractor ile RF sınıflayıcısının performansları Tablo 4.7'de gösterilmiştir.

Tablo 4.7: Gerçek Veri Seti için RF sınıflandırıcısının karmaşıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	94.87	98.67	96.73	88%
	au	85.00	90.67	87.74	
	aud	81.48	88.00	84.62	
	auu	83.93	62.67	71.76	
	ud	96.15	100.00	98.04	
	uu	90.91	93.33	92.11	
InceptionV3	ad	94.81	97.33	96.05	85%
	au	76.74	88.00	81.99	
	aud	78.67	78.67	78.67	
	auu	82.14	61.33	70.23	
	ud	90.24	98.67	94.27	
	uu	87.84	86.67	87.25	
MobileNetV2	ad	92.50	98.67	95.48	83%
	au	79.31	92.00	85.19	
	aud	74.24	65.33	69.50	
	auu	68.25	57.33	62.32	
	ud	96.00	96.00	96.00	
	uu	84.81	89.33	87.01	

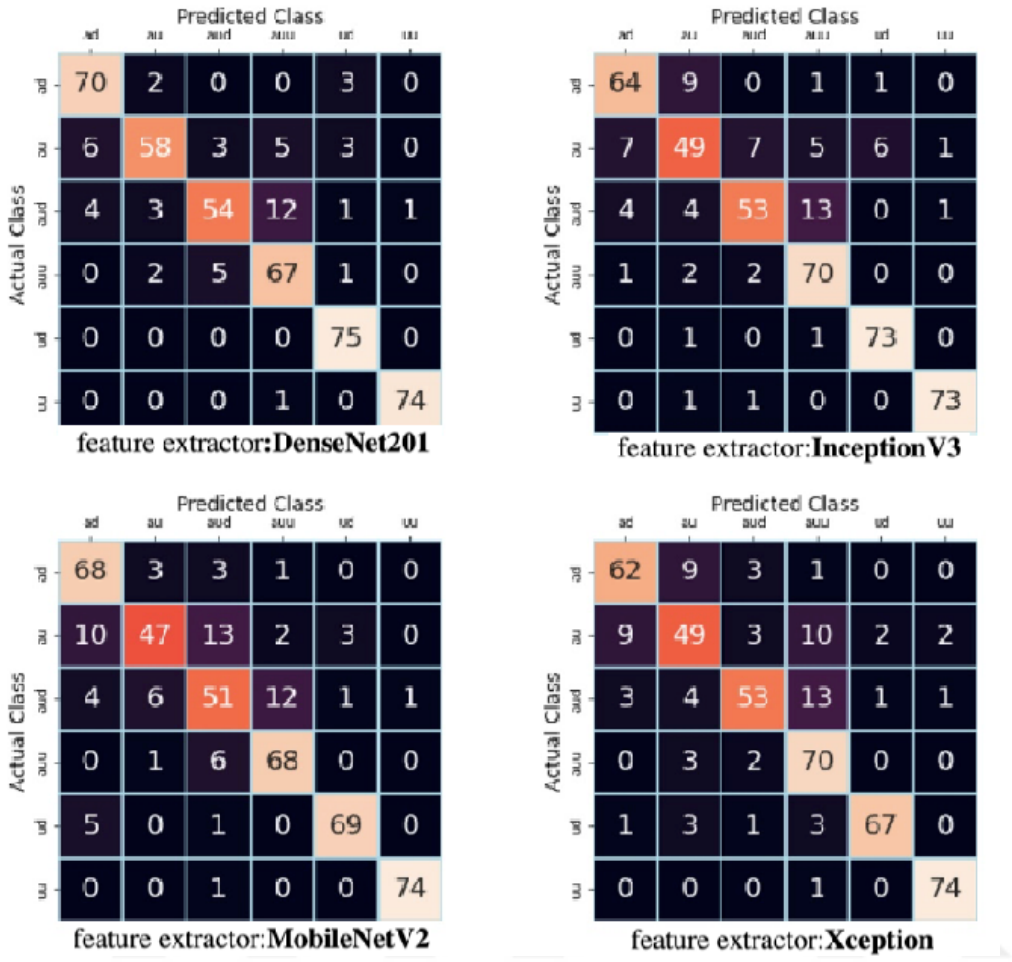
Tablo 4.7.(Devamı)

Xception	ad	93.51	96.00	94.74	84%
	au	77.38	86.67	81.76	
	aud	78.57	73.33	75.86	
	auu	72.88	57.33	64.18	
	ud	96.10	98.67	97.37	
	uu	86.75	96.00	91.14	

Gerçek Veri Seti için Tablo 4.7'de sunulan sonuçlar incelendiğinde, feature extraction için DenseNet201, InceptionV3, MobileNetV2 ve Xception modellerini kullanan RF sınıflandırıcısının sırasıyla %88, %85, %83 ve %84 genel doğruluk(accuracy) performansı gösterdiği görülmektedir. Özellik çıkarıcı olarak RF sınıflandırıcı modeliyle DenseNet201 en iyi performansı göstermiştir.

4.3.1.6. Hibrit Veri Seti İçin RF Sınıflandırıcısının Analiz Sonuçları

Hibrit Veri Seti için RF sınıflayıcısına ait karmaşıklık (confusion) matrisleri Şekil 4.8'de gösterilmiştir.



Şekil 4.8: Hibrit Veri Seti için RF sınıflandırıcısının karışıklık(confusion) matrisleri

Hibrit Veri Seti üzerinde eğitilmiş dört farklı CNN Feature Extractor ile RF sınıflayıcısının performansları Tablo 4.8'de gösterilmiştir.

Tablo 4.8: Hibrit Veri Seti için RF sınıflandırıcısının karmaşıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	0.88	0.93	0.90	88%
	au	0.89	077	0.83	
	aud	0.87	0.72	0.79	
	auu	0.79	0.89	0.84	
	ud	0.90	1.00	0.95	
	uu	0.99	0.99	0.99	
InceptionV3	ad	0.84	0.85	0.85	85%
	au	0.74	0.65	0.70	
	aud	0.84	0.71	0.77	
	auu	0.78	0.93	0.85	
	ud	0.91	0.97	0.94	
	uu	0.97	0.97	0.97	
MobileNetV2	ad	0.78	0.91	0.84	84%
	au	0.82	0.63	0.71	
	aud	0.68	0.68	0.68	
	auu	0.82	0.91	0.86	
	ud	0.85	0.92	0.93	
	uu	0.99	0.99	0.99	

Tablo 4.8(Devamı)

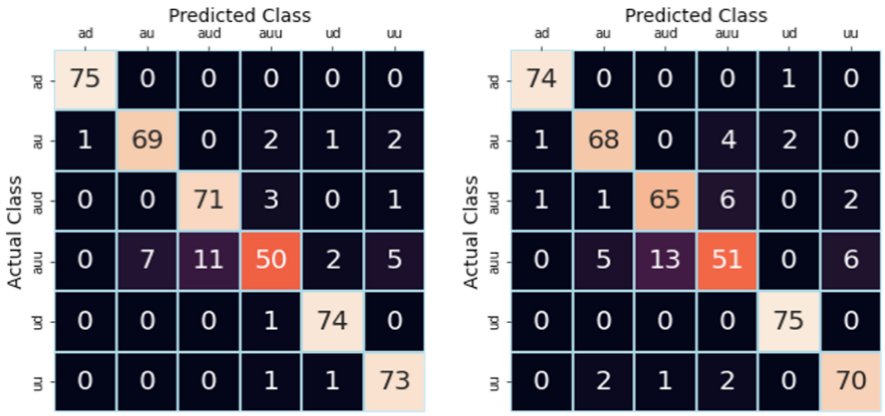
Xception	ad	0.83	0.83	0.83	83%
	au	0.72	0.65	0.69	
	aud	0.85	0.71	0.77	
	auu	0.71	0.93	0.81	
	ud	0.96	0.89	0.92	
	uu	0.96	0.99	0.97	

Hibrit Veri Seti için Tablo 4.8'de sunulan sonuçlar incelendiğinde, feature extraction için DenseNet201, InceptionV3, MobileNetV2 ve Xception modellerini kullanan RF sınıflandırıcısının sırasıyla %88, %85, %84 ve %83 genel doğruluk(accuracy) performansı gösterdiği görülmektedir. Özellik çıkarıcı olarak RF sınıflandırıcı modeliyle DenseNet201 en iyi performansı göstermiştir.

XGB Sınıflayıcısının Analiz Sonuçları

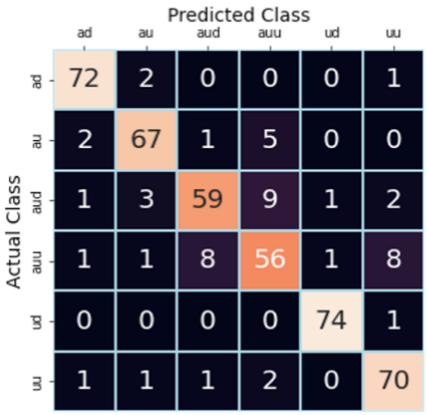
4.3.1.7. Gerçek Veri Seti İçin XGB Sınıflandırıcısının Analiz Sonuçları

Gerçek Verti Seti için XGB sınıflayıcısına ait karmaşıklık (confusion) matrisleri Şekil 4.9'da gösterilmiştir.

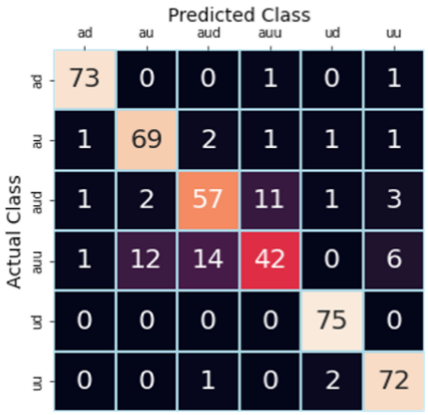


Feature extractor: **DenseNet201**

Feature extractor: **InceptionV3**



Feature extractor: **MobileNetV2**



Feature extractor: **Xception**

Şekil 4.9: Gerçek Veri Seti için XGB sınıflandırıcısının karışıklık(confusion) matrisleri

Gerçek Veri Seti üzerinde eğitilmiş dört farklı CNN Feature Extractor ile XGB sınıflayıcısının performansları Tablo 4.9'da gösterilmiştir.

Tablo 4.9: Gerçek Veri Seti için XGB sınıflandırıcısının karmaşıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	98.68	100.00	99.34	%91
	au	90.79	92.00	91.39	
	aud	86.59	94.67	90.45	
	auu	87.72	66.67	75.76	
	ud	94.87	98.67	96.73	
	uu	90.12	97.33	93.59	
InceptionV3	ad	97.37	98.67	98.01	%89
	au	89.47	90.67	90.07	
	aud	82.28	86.67	84.42	
	auu	80.95	68.00	73.91	
	ud	96.15	100.00	98.04	
	uu	89.74	93.33	91.50	
MobileNetV2	ad	93.51	96.00	94.74	%88
	au	90.54	89.33	89.93	
	aud	85.51	78.67	81.94	
	auu	77.78	74.67	76.19	
	ud	97.37	98.67	98.01	
	uu	85.37	93.33	89.17	

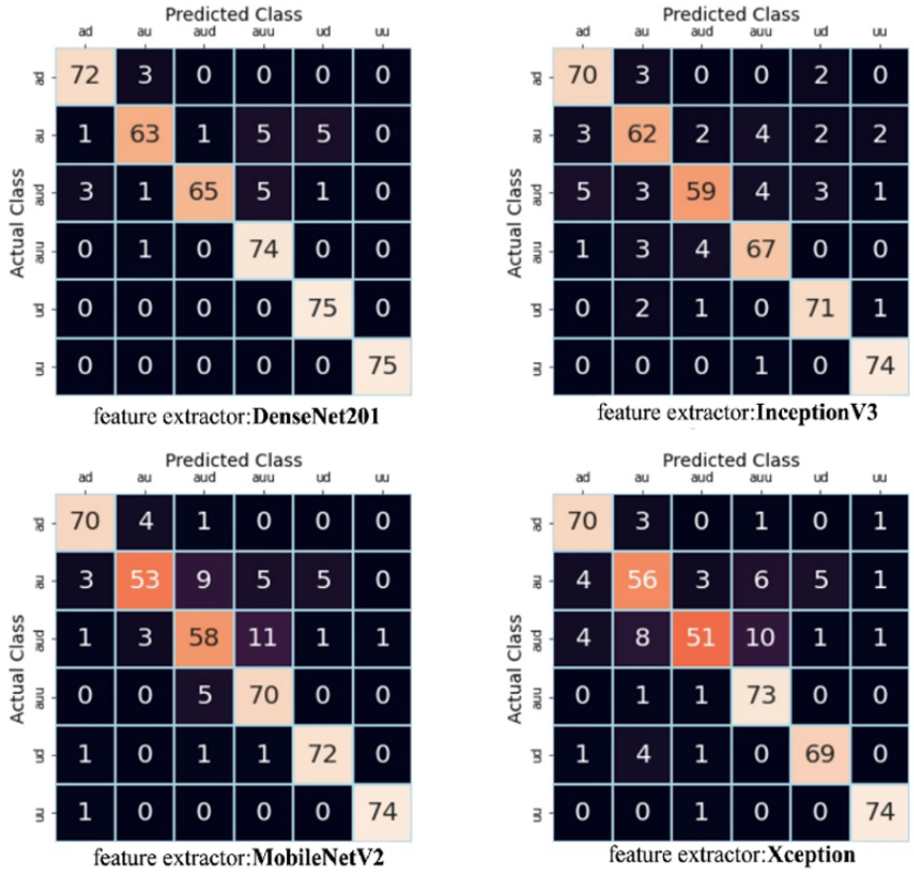
Tablo 4.9(Devamı)

Xception	ad	96.05	97.33	96.69	%86
	au	83.13	92.00	87.34	
	aud	77.03	76.00	76.51	
	auu	76.36	56.00	64.62	
	ud	94.94	100.00	97.40	
	uu	86.75	96.00	91.14	

Gerçek Veri Seti için Tablo 4.9'da sunulan sonuçlar incelendiğinde, feature extraction için DenseNet201, InceptionV3, MobileNetV2 ve Xception modellerini kullanan XGB sınıflandırıcısının sırasıyla %91, %89, %88 ve %86 genel doğruluk(accuracy) performansı gösterdiği görülmektedir. Özellik çıkarıcı olarak XGB sınıflandırıcı modeliyle DenseNet201 en iyi performansı göstermiştir.

4.3.1.8. Hibrit Veri Seti İçinXGB Sınıflandırıcısının Analiz Sonuçları

Hibrit Verti Seti için XGB sınıflayıcısına ait karmaşıklık (confusion) matrisleri Şekil 4.10'da gösterilmiştir.



Şekil 4.10: Hibrit Veri Seti için XGB sınıflandırıcısının karışıklık(confusion) matrisleri

Hibrit Veri Seti üzerinde eğitilmiş dört farklı CNN Feature Extractor ile XGB sınıflayıcısının performansları Tablo 4.10'da gösterilmiştir.

Tablo 4.10: Hibrit Veri Seti içinXGB sınıflandırıcısının karmaşıklık matrisi sonuçları

MODELLER	SINIFLAR	KESİNLİK	DUYARLILIK	F1 SKORU	GENEL DOĞRULUK
DenseNet201	ad	0.95	0.96	0.95	94%
	au	0.93	0.84	0.88	
	aud	0.98	0.87	0.92	
	auu	0.88	0.99	0.93	
	ud	0.93	1.00	0.96	
	uu	1.00	1.00	1.00	
InceptionV3	ad	0.89	0.93	0.91	90%
	au	0.85	0.83	0.84	
	aud	0.89	0.79	0.84	
	auu	0.88	0.89	0.89	
	ud	0.91	0.95	0.93	
	uu	0.95	0.99	0.97	
MobileNetV2	ad	0.92	0.93	0.93	88%
	au	0.88	0.71	0.79	
	aud	0.78	0.77	0.78	
	auu	0.80	0.93	0.86	
	ud	0.92	0.96	0.84	
	uu	0.99	0.99	0.99	

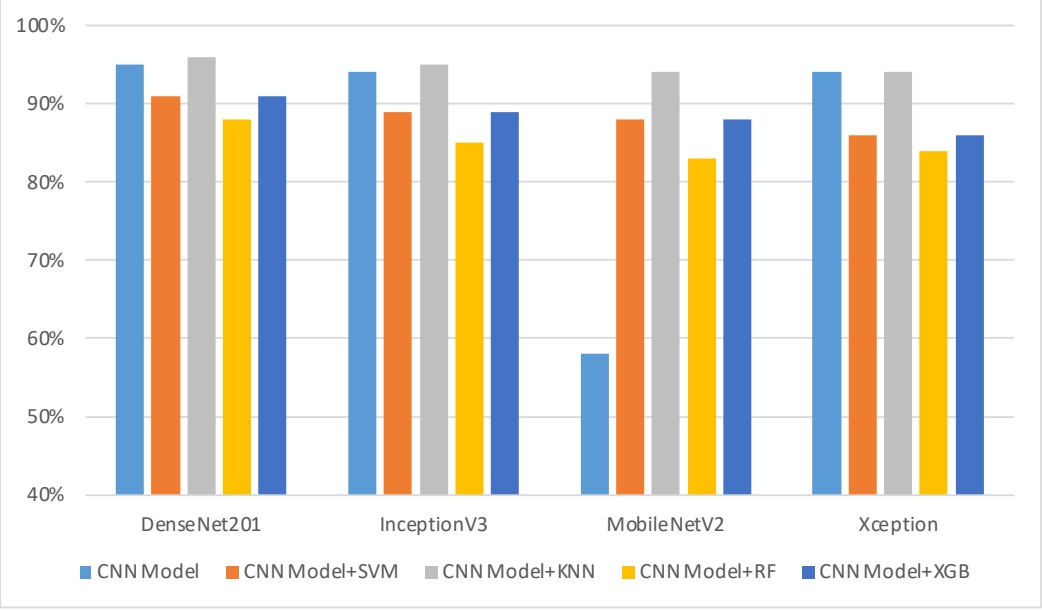
Tablo 4.10(Devamı)

Xception	ad	0.89	0.93	0.91	87%
	au	0.78	0.75	0.76	
	aud	0.89	0.68	0.77	
	auu	0.81	0.97	0.88	
	ud	0.92	0.92	0.92	
	uu	0.96	0.99	0.97	

Hibrit Veri Seti için Tablo 4.10'da sunulan sonuçlar incelendiğinde, feature extraction için DenseNet201, InceptionV3, MobileNetV2 ve Xception modellerini kullanan XGB sınıflandırıcısının sırasıyla %94, %90, %88 ve %87 genel doğruluk(accuracy) performansı gösterdiği görülmektedir. Özellik çıkarıcı olarak XGB sınıflandırıcı modeliyle DenseNet201 en iyi performansı göstermiştir.

Modellerin Performans Analizi

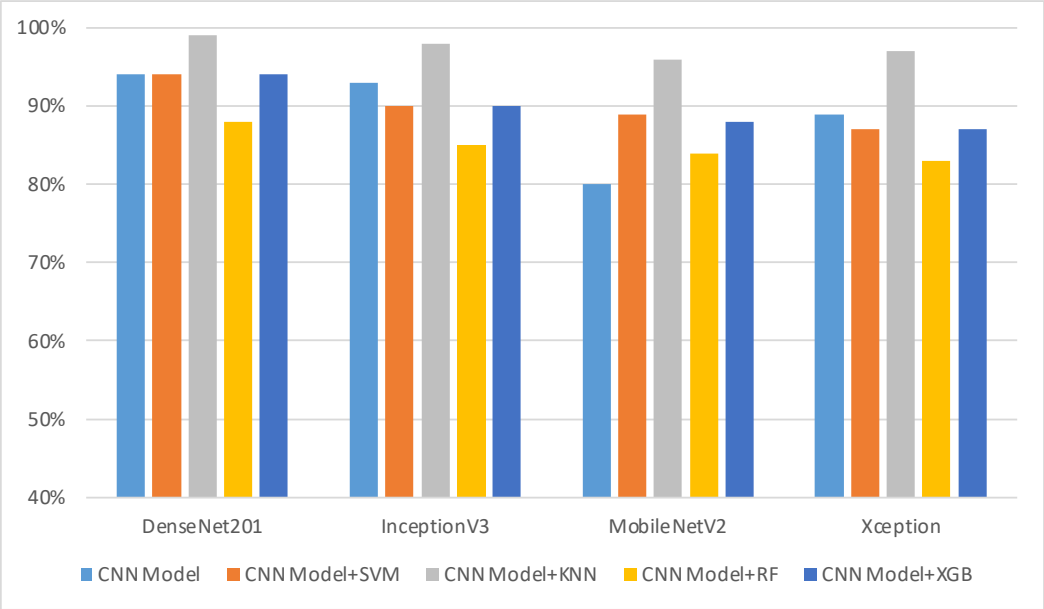
4.3.1.9. Gerçek Veri Seti İçin Modellerin Performans Analizi



Şekil 4.11: Gerçek Veri Seti için Modellerin performans oranları

Gerçek Veri Seti için Şekil 4.11 incelendiğinde, DenseNet201(özellik çıkarıcı)+KNN modeli(sınıflandırıcı) eksik dişlerin implant uygunluğunu belirlemek için önerilen yöntemler arasında %96 genel doğrulukla en yüksek başarıyı göstermiştir. Ayrıca, KNN sınıflandırıcı çalışmada kullanılan CNN modellerinin başarısını artırmıştır. Özellikle MobileNetV2'nin başarısını ciddi ölçüde arttırmıştır. RF sınıflandırıcı MobileNetV2 modeli hariç CNN modellerinin başarısını azaltmıştır.

4.3.1.10. Hibrit Veri Seti İçin Modellerin Performans Analizi



Şekil 4.12: Hibrit Veri Seti için Modellerin performans oranları

Hibrit Veri Seti için Şekil 4.12 incelendiğinde, DenseNet201(özellik çıkarıcı)+KNN modeli(sınıflandırıcı) eksik dişlerin implant uygunluğunu belirlemek için önerilen yöntemler arasında %99 genel doğrulukla en yüksek başarıyı göstermiştir. Ayrıca, KNN sınıflandırıcı çalışmada kullanılan CNN modellerinin başarısını artırmıştır. RF sınıflandırıcı MobileNetV2 modeli hariç CNN modellerinin başarısını azaltmıştır.

5. TARTIŞMA

Bu çalışmada geliştirilen derin öğrenme tabanlı sistemin, panoramik diş röntgenleri üzerinden eksik diş tespiti ve implant uygunluğu değerlendirmesinde yüksek doğrulukla çalıştığı görülmüştür. Özellikle hibrit veri seti üzerinde DenseNet201 + KNN modeli %99 genel doğrulukla en yüksek başarıyı göstermiştir. Bu sonuç, Chen ve diğ.(2022) tarafından GoogLeNet ile ulaşılan %97.1 doğruluğun da ötesindedir [25]. Ayrıca, Mertoğlu ve Keser(2023) tarafından Faster R-CNN kullanılarak elde edilen %99.6 duyarlılıkla benzer düzeyde başarı gösterilmiştir [20]. Ancak bu çalışmalarda yalnızca eksik diş tespiti hedeflenmişken, bu araştırmada implant uygunluğu da entegre biçimde ele alınarak daha kapsamlı bir değerlendirme sunulmuştur.

Park ve diğ. (2022), eksik diş tespiti ve implant planlamasını iki aşamalı bir segmentasyon ve tespit yöntemiyle gerçekleştirmiştir. Buna karşın, bu çalışmada segmentasyon süreci yerine doğrudan sınıflandırma temelli bir yaklaşım tercih edilmiştir. Bu durum, sistemin daha düşük hesaplama maliyetiyle çalışmasını ve klinik ortamlarda daha hızlı sonuç üretmesini sağlamaktadır. Ayrıca, literatürde yaygın olarak kullanılan Mask R-CNN gibi modellerin yüksek doğruluğuna rağmen işlem sürelerinin uzunluğu bu çalışmada doğrudan sınıflandırma modellerinin kullanımını daha avantajlı kılmıştır [29, 11].

Her iki veri seti için de KNN sınıflandırıcının, tüm CNN mimarileriyle birlikte çalışıldığında model başarısını artırdığı gözlenmiştir. Bu durum, literatürde doğrudan vurgulanmamış olsa da, KNN'nin veri noktaları arasındaki mesafeye dayalı karar verme özelliğinin eksik diş gibi sınırlı sayıda örnek içeren durumlarda avantaj sağladığı şeklinde yorumlanabilir. Öte yandan, RF sınıflandırıcının MobileNetV2 modeli dışında genel olarak doğruluğu düşürdüğü görülmüştür. Bu durum, RF'nin karmaşık veri yapılarında aşırı uyum (overfitting) riskini artırmasıyla ilişkilendirilebilir.

Mevcut çalışmaların büyük kısmı sınırlı görüntü sayısı ile yürütülmüştür (örn. 108 panoramik görüntü [25]). Bu çalışmada kullanılan geniş ve çeşitlendirilmiş veri seti

sayesinde, modelin genelleme yeteneği önemli ölçüde artırılmıştır. Ayrıca, yalnızca eksik dişin tespiti değil, implant yerleştirme açısından uygunluk da sınıflandırılarak, gerçek klinik karar destek sistemlerine daha yakın bir yapı oluşturulmuştur.

Sonuç olarak, bu çalışma eksik dişlerin tespitini ve implant planlamasını entegre şekilde gerçekleştiren özgün bir model önererek literatüre önemli bir katkı sunmaktadır. Klinik uygulamalarda hem tanı doğruluğunu hem de işlem hızını artırma potansiyeli taşıyan sistem, gelecekte gerçek zamanlı yapay zekâ destekli karar destek araçlarının geliştirilmesine temel oluşturabilir.

6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, panoramik dental radyografiler üzerinde eksik dişlerin tespiti ve bu eksik alanların implant yerleştirilmesine uygunluğunun değerlendirilmesine yönelik yapay zekâ tabanlı entegre bir model geliştirilmiştir. Literatürde genellikle ayrı ayrı ele alınan bu iki sürecin birlikte değerlendirildiği altı sınıflı sınıflandırma yaklaşımı, hem modelleme hem de klinik uygulama açısından yenilikçi bir katkı sağlamıştır. Yapılan deneysel analizler sonucunda ulaşılan başlıca bulgular aşağıda özetlenmiştir:

- Geliştirilen entegre sistem, eksik dişlerin tespitiyle birlikte bu bölgelerin implant açısından uygunluk durumunu da değerlendirerek, klinik kararlara çift yönlü destek sunmaktadır.
- Çalışmada kullanılan DenseNet201 + KNN modeli, Hibrit Veri Seti'nde %99, Gerçek Veri Seti'nde ise %96 genel doğruluk oranı ile tüm yöntemler arasında en yüksek başarıyı göstermiştir.
- Her iki veri seti için de kullanılan dört farklı CNN modeli (DenseNet201, InceptionV3, MobileNetV2, Xception) geleneksel sınıflayıcılarla (SVM, KNN, RF, XGB) birlikte değerlendirilmiş ve KNN sınıflayıcının tüm modellerde

başarıyı artırdığı, RF sınıflayıcının ise yalnızca MobileNetV2 modeli dışında genellikle başarıyı düşürdüğü görülmüştür.

- Hibrit Veri Seti'ndeki başarı oranları genel olarak Gerçek Veri Seti'ne göre daha yüksektir. Bu durum, dengeli ve çeşitli verilerin model performansını olumlu yönde etkilediğini göstermektedir.
- Segmentasyon tabanlı yöntemlerin aksine, bu çalışmada doğrudan sınıflandırma yaklaşımı ile daha düşük hesaplama maliyetine sahip, hızlı ve bütünleşik bir sistem önerilmiştir. Bu yönüyle sistemin klinik kullanıma daha uygun olduğu düşünülmektedir.

Bu bulgular doğrultusunda, gelecekte yapılacak çalışmalarda geliştirilen sistemin farklı yaş grupları, cinsiyetler ve sistemik hastalık durumları gibi demografik faktörlere göre özelleştirilmesi önerilmektedir. Ayrıca, modelin üç boyutlu görüntüleme verileri (örneğin CBCT) ile desteklenmesi, implant yerleştirme uygunluğunu daha hassas biçimde değerlendirebilme imkânı sunabilir. Radyolojik parametreler (örneğin kemik yoğunluğu, sinüs pozisyonu) sisteme entegre edilerek anatomik analiz derinleştirilebilir. Klinik ortamda gerçek zamanlı karar destek sistemine dönüştürülmesi hâlinde, bu yapay zekâ temelli yaklaşımın diş hekimlerine tanı ve tedavi planlamasında önemli katkılar sağlayacağı öngörülmektedir. Ayrıca veri setinin genişletilmesi, modelin genellenebilirliğini ve farklı klinik senaryolara uyarlanabilirliğini artıracaktır. Son olarak, farklı radyografi cihazlarından elde edilen panoramik görüntülerle aynı çalışmanın tekrarlanması, modelin cihazlar arası uyumunu ve dayanıklılığını test etmek açısından faydalı olacaktır.

KAYNAKLAR

[1] Topol, E., 2019. *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again*. Basic Books.

[2] Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K. ve Dean, J., 2019. A guide to deep learning in healthcare. *Nature Medicine*, 25(1), ss.24–29. https://doi.org/10.1038/s41591-018-0316-z.

[3] Miotto, R., Wang, F., Wang, S., Jiang, X. ve Dudley, J.T., 2018. Deep learning for healthcare: review, opportunities and challenges. *Briefings in Bioinformatics*, 19(6), ss.1236–1246. https://doi.org/10.1093/bib/bbx044.

[4] Jumper, J., Evans, R., Pritzel, A. ve diğ., 2021. Highly accurate protein structure prediction with AlphaFold. *Nature*, 596, ss.583–589. https://doi.org/10.1038/s41586-021-03819-2.

[5] Kositbowornchai, S., Plermkamon, S. ve Sinthanayothin, C., 2006. A method for detecting proximal caries in dental digital radiographs using fuzzy logic and neural networks. *International Journal of Computer Assisted Radiology and Surgery*, 1, ss.49–53. https://doi.org/10.1007/s11548-006-0031-3.

[6] Javed, K., Jalal, A. ve Kim, K., 2021. Dental diseases detection using YOLOv3 deep convolutional neural network. *IEEE Access*, 9, ss.97228–97244. https://doi.org/10.1109/ACCESS.2021.3092955.

[7] Lee, J.H., Kim, D.H., Jeong, S.N. ve Choi, S.H., 2018. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of Dentistry*, 77, ss.106–111. https://doi.org/10.1016/j.jdent.2018.07.015.

[8] Abdalla-Aslan, R., Yeshua, T., Kabla, D., Leichter, I. ve Nadler, C., 2020. An artificial intelligence system using machine learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 130(5), ss.593–602. https://doi.org/10.1016/j.oooo.2020.05.012.

[9] Bahar, A., Afifi, A.M. ve Youssef, S.M., 2022. Deep learning-based third molar angle classification in panoramic dental radiographs. *Computer Methods and Programs in Biomedicine*, 226, 107125. https://doi.org/10.1016/j.cmpb.2022.107125.

[10] Revilla-León, M., Gómez-Polo, M., Vyas, S., Barmak, A.B., Gallucci, G.O., Att, W. ve diğ., 2023. Artificial intelligence models for tooth-supported fixed and removable prosthodontics: A systematic review. *Journal of Prosthetic Dentistry*, 129(2), ss.276–292. [Erişim tarihi: 29 Mayıs 2024], https://doi.org/10.5167/uzh-256388.

[11] Rubiu, G., Bologna, M., Cellina, M., Cè, M., Sala, D., Pagani, R. ve diğ., 2023. Teeth segmentation in panoramic dental X-ray using Mask Regional

Convolutional Neural Network. *Applied Sciences*, 13(13), 7947. https://doi.org/10.3390/app13137947.

[12] Zadrożny, Ł., Regulski, P., Brus-Sawczuk, K., Czajkowska, M., Parkanyi, L., Ganz, S. ve diğ., 2022. Artificial intelligence application in assessment of panoramic radiographs. *Diagnostics (Basel)*, 12(1), 224. https://doi.org/10.3390/diagnostics12010224.

[13] Milosevic, D., Vodanovic, M., Galic, I. ve Subasic, M., 2019. Estimating biological gender from panoramic dental X-ray images. *11th International Symposium on Image and Signal Processing and Analysis (ISPA)*, 23–25 Ekim 2019, Dubrovnik, Hırvatistan. IEEE, ss.105–110. https://doi.org/10.1109/ISPA.2019.8868804.

[14] Lee, S., Kim, D. ve Jeong, H.G., 2022. Detecting 17 fine-grained dental anomalies from panoramic dental radiography using artificial intelligence. *Scientific Reports*, 12, 5172. https://doi.org/10.1038/s41598-022-09083-2.

[15] ALbahbah, A.A., El-Bakry, H.M. ve Abd-Elgahany, S., 2016. Detection of caries in panoramic dental X-ray images using back-propagation neural network. *International Journal of Electronic Communication and Computer Engineering*, 7(5), ss.2249–071X.

[16] Oztekin, F., Katar, O., Sadak, F., Yildirim, M., Cakar, H., Aydogan, M. ve diğ., 2023. An explainable deep learning model to predict dental caries using panoramic radiograph images. *Diagnostics*, 13(2), 20226. https://doi.org/10.3390/diagnostics13020226.

[17] Ali, M.A., Fujita, D. ve Kobashi, S., 2023. Teeth and prostheses detection in dental panoramic X-rays using CNN-based object detector and a priori knowledge-based algorithm. *Scientific Reports*, 13, 16542. https://doi.org/10.1038/s41598-023-43591-z.

[18] Chung, M., Lee, J., Park, S., Lee, M., Lee, C.E., Lee, J. ve Shin, Y.G., 2021. Individual tooth detection and identification from dental panoramic X-ray images via point-wise localization and distance regularization. *Artificial Intelligence in Medicine*, 111, 101996. https://doi.org/10.1016/j.artmed.2020.101996.

[19] Hasnain, M.A., Ali, S., Malik, H., Irfan, M., Maqbool, M.S., Muresan, M.P. ve diğ., 2023. Deep learning-based classification of dental disease using X-rays. *Journal of Computational Biomedical Informatics*, 5(1). https://doi.org/10.56979/501/2023.

[20] Mertoglu, D., Keser, G., Namdar Pekiner, F.M., Bayrakdar, I.S., Celik, O. ve Orhan, K., 2023. A deep learning approach to automatic tooth detection and numbering in panoramic radiographs: An artificial intelligence study. *Clinical and Experimental Health Sciences*, 13(4), ss.883–888. https://doi.org/10.33808/clinexphealthsci.1219160.

[21] Muresan, M.P., Barbura, R. ve Nedevschi, S., 2020. Teeth detection and dental problem classification in panoramic X-ray images using deep learning and image processing techniques. *16th IEEE International Conference on Intelligent Computer Communication and Processing (ICCP)*, Eylül 2020, Cluj-Napoca, Romanya. IEEE. https://doi.org/10.1109/ICCP51029.2020.9266244.

[22] Tuzoff, D.V., Tuzova, L.N., Bornstein, M.M., Krasnov, A.S., Kharchenko, M.A., Nikolenko, S.I., Sveshnikov, M.M. ve Bednenko, G.B., 2019. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology*, 48(4), 20180051. https://doi.org/10.1259/dmfr.20180051.

[23] Umer, F., Habib, S. ve Adnan, N., 2022. Application of deep learning in teeth identification tasks on panoramic radiographs. *Dentomaxillofacial Radiology*, 51(5), 20210504. https://doi.org/10.1259/dmfr.20210504.

[24] Yuksel, A.E., Gultekin, S., Simsar, E., Ozdemir, S.D., Gündogar, M., Tokgoz, S.B. ve diğ., 2021. Dental enumeration and multiple treatment detection on panoramic X-rays using deep learning. *Scientific Reports*, 11(1), 12342. https://doi.org/10.1038/s41598-021-90386-1.

[25] Chen, S.L., Chen, T.Y., Huang, Y.C., Chen, C.A., Chou, H.S. ve Huang, Y.Y., 2022. Missing teeth and restoration detection using dental panoramic radiography based on transfer learning with CNNs. *IEEE Access*, 10, ss.118654–118664. https://doi.org/10.1109/ACCESS.2022.3220335.

[26] Amasya, H., Jaju, P.P., Ezhov, M., Gusarev, M., Atakan, C., Sanders, A. ve diğ., 2024. Development and validation of an artificial intelligence software for periodontal bone loss in panoramic imaging. *International Journal of Imaging Systems and Technology*, 34(1), 1. https://doi.org/10.1002/ima.22973.

[27] Ha, E.-G., Jeon, K.J., Kim, Y.H., Kim, J.-Y. ve Han, S.S., 2021. Automatic detection of mesiodens on panoramic radiographs using artificial intelligence. *Scientific Reports*, 11(1), 23061. https://doi.org/10.1038/s41598-021-02571-x.

[28] Nilsson, T., Lundgren, T., Odelius, H., Sillén, R. ve Norén, J.G., 1996. A computerized induction analysis of possible co-variations among different elements in human tooth enamel. *Artificial Intelligence in Medicine*, 8(6), ss.515–526. https://doi.org/10.1016/s0933-3657(96)00350-8.

[29] Jader, G., Fontineli, J., Ruiz, M., Buzar Lima, K.A., Pithon, M. ve Oliveira, L., 2018. Deep instance segmentation of teeth in panoramic X-ray images. *31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, Ekim 2018. https://doi.org/10.1109/SIBGRAPI.2018.00058.

[30] Leite, A.F., Van Gerven, A., Willems, H., Beznik, T., Lahoud, P., Gaêta-Araujo, H., Vranckx, M. ve Jacobs, R., 2021. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clinical Oral Investigations*, 25(4), ss.2257–2267.https://doi.org/10.1007/s00784-020-03544-6.

[31] Wirtz, A., Mirashi, S.G. ve Wesarg, S., 2018. Automatic teeth segmentation in panoramic X-ray images using a coupled shape model in combination with a neural network. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2018: 21st International Conference*, Granada, İspanya, 16–20 Eylül 2018. *Lecture Notes in Computer Science*, Bölüm IV, ss.712–719. https://doi.org/10.1007/978-3-030-00937-3_81.

[32] GUIZ, A., 1995. *Comparative qualitative and quantitative evaluation of the suitability of the selected area in endosseous implants using panoramic radiography and computed tomography*. Doktora Tezi. İzmir: Ege Üniversitesi Sağlık Bilimleri Enstitüsü.

[33] Bozkurt, M.H. ve Karagol, S., 2023. Statistical elimination based approach to jaw and tooth separation on panoramic radiographs for dental human identification. *Multimedia Tools and Applications*, 82(21), ss.32117–32150. https://doi.org/10.1007/s11042-023-14746-x.

[34] Park, J., Lee, J., Moon, S. ve Lee, K., 2022. Deep learning based detection of missing tooth regions for dental implant planning in panoramic radiographic images. *Applied Sciences*, 12(3), 1595. https://doi.org/10.3390/app12031595.

[35] Humans in the Loop, 2023. *Teeth Segmentation on Dental X-ray Images* [veri seti]. Humans in the Loop. https://humansintheloop.org/resources/datasets/teeth-segmentation-dataset/ [Erişim tarihi: 29 Mayıs 2024].

[36] Hexthext, 2023. *Dental Dataset* [veri seti]. Kaggle. https://www.kaggle.com/datasets/hexthext/dental [Erişim tarihi: 15 Ocak 2025].

[37] Román, J.C.M., Fretes, V.R., Adorno, ve diğ., 2021. Panoramic dental radiography image enhancement using multiscale mathematical morphology. *Sensors*, 21(9), 3110. https://doi.org/10.3390/s21093110.

[38] Shorten, C. ve Khoshgoftaar, T.M., 2019. A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), ss.1–48.

[39] Perez, L. ve Wang, J., 2017. The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint*, arXiv:1712.04621.

[40] Wang, X., ve diğ., 2017. ChestX-ray8: Hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, ss.3462–3471.

[41] Salehinejad, H., ve diğ., 2018. Generalization of deep neural networks for chest pathology classification in X-rays using GANs. *ICASSP: IEEE International Conference on Acoustics, Speech and Signal Processing*, ss.990–994.

[42] Xu, M., ve diğ., 2022. Data augmentation strategies in dental image analysis: A review. *Computers in Biology and Medicine*, 144, 105391.

[43] Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K.Q., 2017. Densely connected convolutional networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, ss.4700–4708. https://doi.org/10.1109/CVPR.2017.243.

[44] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z., 2016. Rethinking the Inception architecture for computer vision. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, ss.2818–2826. https://doi.org/10.1109/CVPR.2016.308.

[45] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. ve Chen, L.C., 2018. MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, ss.4510–4520. https://doi.org/10.1109/CVPR.2018.00474.

[46] Chollet, F., 2017. Xception: Deep learning with depthwise separable convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, ss.1251–1258. https://doi.org/10.1109/CVPR.2017.195.

[47] Cortes, C. ve Vapnik, V., 1995. Support-vector networks. *Machine Learning*, 20(3), ss.273–297. https://doi.org/10.1007/BF00994018.
[48] Cover, T. ve Hart, P., 1967. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), ss.21–27. https://doi.org/10.1109/TIT.1967.1053964.
[49] Breiman, L., 2001. Random forests. *Machine Learning*, 45(1), ss.5–32. https://doi.org/10.1023/A:1010933404324.
[50] Chen, T. ve Guestrin, C., 2016. XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*, 13–17 Ağustos 2016, San Francisco, CA, USA. New York: ACM, ss.785–794.

Evrak Tarih ve Sayısı: 06.12.2024-33800

T.C.
SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
HAMİDİYE BİLİMSEL ARAŞTIRMALAR ETİK KURULU

Toplantı Tarihi : 28.11.2024
Toplantı Sayısı : 2024/14
Karar Sayısı : 14/27

Kurulumuza değerlendirilmek üzere sunulan Doç. Dr. Sibel Senan'ın sorumlu, Elifnur Güzelce Sultanoğlu ve Nurefşan Güzelce Kuyulu'nun yardımcı araştırmacı olduğu 24/733 kayıt numaralı **"Panoramik Diş Röntgenlerinde Diş Eksikliklerinin Makine Öğrenmesi Kullanılarak Tespiti ve Sınıflandırılması"** başlıklı proje önerisi kurulumuzun 28.11.2024 tarihli toplantısında değerlendirilmiş ve etik açıdan uygun bulunmuştur.

Doç. Dr. Yasemin AYDIN KARTAL
Başkan

Doç. Dr. Muzaffer AKDOĞAN
Başkan Yardımcısı

Prof. Dr. Papatya KELEŞ
Etik Kurul Üyesi

Prof. Dr. Abubekir ELTAS
Etik Kurul Üyesi

Prof. Dr. Günseli GÜVEN POLAT
Etik Kurul Üyesi

Prof. Dr. Neslihan ÜSTÜNDAĞ OKUR
Etik Kurul Üyesi

Prof. Dr. Mazhar Müslüm TUNA
Etik Kurul Üyesi

Prof. Dr. Selda RIZALAR
Etik Kurul Üyesi

Doç. Dr. Eray Metin GÜLER
Etik Kurul Üyesi

Doç. Dr. Gamze TEMİZ
Etik Kurul Üyesi

Doç. Dr. Yıldız BİLGE
Etik Kurul Üyesi

Dr. Öğr. Üyesi Banu BAYRAM
Etik Kurul Üyesi

Dr. Öğr. Üyesi Hasan DEMİRCİ
Öğretim Üyesi

29.11.2024 Memur Feyzanur SEZGİN

Evrakı Doğrulamak İçin : https://www.turkiye.gov.tr/sbu-ebys?eD=BSU65E6VEK&eS=33800

Bu belge 5070 sayılı Elektronik İmza Kanununun 5. Maddesi gereğince güvenli elektronik imza ile imzalanmıştır.

KURUM İZNİ YAZILARI

Uyarı: Canlı ve cansız deneklerle yapılan tüm çalışmalar için kurum izin belgelerinin eklenmesi zorunludur. Gizlilik ve mahremiyet içeren durumlarda kurum adı kapatılmalıdır.

☒ **Kurum izni gerekmektedir.**

☐ **Kurum izni gerekmemektedir.**

Nurefşan GÜZEL GÜZELCE

İSTANBUL İL SAĞLIK MÜDÜRLÜĞÜ EVRAK BİRİMİ
İSTANBUL İL SAĞLIK MÜDÜRLÜĞÜ EVRAK BİRİMİ
28.02.2024 10:03:37 E-71211201-000-237923681
237923681

T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
REKTÖRLÜĞÜ
Öğrenci İşleri Daire Başkanlığı

Sayı : E-97248701-300-927605 28.02.2024
Konu : Tez Çalışma İzni-Nurefşan GÜZELCE KUYULU

DAĞITIM YERLERİNE

Üniversitemiz Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalında görevli Doç. Dr. Sibel SENAN'ın danışmanlığında tezli yüksek lisans eğitimine devam eden Nurefşan GÜZELCE KUYULU'nun "Panoramik Diş Röntgenlerinden Diş Eksikliklerinin Makine Öğrenmesi Kullanılarak Tespiti ve Sınıflandırılması" başlıklı tez çalışması kapsamında talep edilen panoramik diş röntgeni görüntü verilerinin kullanım izninin Sağlık Bakanlığı ile Sağlık Bilimleri Üniversitesi Rektörlüğü arasında imzalanan birlikte kullanım protokolü gereği İstanbul Tacirler Eğitim Vakfı Sultanbeyli Ağız ve Diş Sağlığı Eğitim ve Araştırma Hastanesinden alınması gerektiği hakkında Sağlık Bilimleri Üniversitesi Öğrenci İşleri Daire Başkanlığından alınan 26.02.2024 tarihli, E-36960053-300-334478 sayılı yazı ekte gönderilmiştir.

Bu kapsamda panoramik diş röntgeni görüntü verilerinin İstanbul Tacirler Eğitim Vakfı Sultanbeyli Ağız ve Diş Sağlığı Eğitim ve Araştırma Hastanesinden temin edilmesi hususunda bilgilerini ve gereğini rica ederim.

Prof. Dr. Mehmet BİLGİN
Rektör a.
Rektör Yardımcısı

Ek:
1- Sağlık Bilimleri Üniversitesi Rektörlüğüne 19.02.2024 tarihli, 917992 sayılı yazımız.
2- Sağlık Bilimleri Üniversitesi Hamidiye Diş Hekimliği Fakültesi Dekanlığının 26.02.2024 tarihli, 334478 sayılı yazısı.

DAĞITIM:
Gereği:
İstanbul İl Sağlık Müdürlüğüne

Bilgi:
Lisansüstü Eğitim Enstitüsü Müdürlüğü

Bu belge, güvenli elektronik imza ile imzalanmıştır.
Belge Doğrulama Kodu :BS4SKRVAJ3
Belge Takip Adresi : https://www.turkiye.gov.tr/istanbul-universitesi-cerrahpasa-ebys

Adres:İstanbul Üniversitesi-Cerrahpaşa Rektörlüğü, 34320 Avcılar-İstanbul
Telefon:0212 404 03 00 Faks:0212 404 07 01
Web:https://www.iuc.edu.tr
Kep Adresi:iuc@hs01.kep.tr
Bilgi için: Nuray ÖZYER
Dahili: 11334

T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
REKTÖRLÜĞÜ
Öğrenci İşleri Daire Başkanlığı

Sayı : E-97248701-300-917992 19.02.2024
Konu : Tez Çalışma İzni-Nurefşan GÜZELCE KUYULU

SAĞLIK BİLİMLERİ ÜNİVERSİTESİ REKTÖRLÜĞÜNE

Üniversitemiz Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalında Doç. Dr. Sibel SENAN'ın danışmanlığında tezli yüksek lisans eğitimine devam eden Nurefşan GÜZELCE KUYULU'nun "Panoramik Diş Röntgenlerinden Diş Eksikliklerinin Makine Öğrenmesi Kullanılarak Tespiti ve Sınıflandırılması" başlıklı tez çalışması kapsamında Üniversiteniz Hamidiye Diş Hekimliği Fakültesinden panoramik diş röntgeni görüntü verilerini alabilmesi için gerekli iznin verilmesi hakkında adı geçen Enstitü Müdürlüğünden alınan 15.02.2024 tarihli, E-13022260-300-914883 sayılı yazı ekte gönderilmiştir.

Bilgilerini ve gereğini arz ederim.

Prof. Dr. Mehmet BİLGİN
Rektör a.
Rektör Yardımcısı

Ek:Yazı ve Ekleri (7 Sayfa)

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu :BSNSB7VECZ Belge Takip Adresi : https://www.turkiye.gov.tr/istanbul-universitesi-cerrahpasa-ebys

Adres:İstanbul Üniversitesi-Cerrahpaşa Rektörlüğü, 34320 Avcılar-İstanbul
Telefon:0212 404 03 00 Faks:0212 404 07 01
Web:https://www.iuc.edu.tr
Kep Adresi:iuc@hs01.kep.tr

Bilgi için: Nuray ÖZYER
Dahili: 11334

İÜC Tarih ve Sayı: 15.02.2024-914883

T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
REKTÖRLÜĞÜ
Lisansüstü Eğitim Enstitüsü Müdürlüğü

Sayı : E-13022260-300-914883 15.02.2024
Konu : Nurefşan GÜZELCE KUYULU tez çalışma izni

İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA REKTÖRLÜĞÜNE
(Öğrenci İşleri Daire Başkanlığı)

Enstitümüz Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Programı öğrencisi Nurefşan GÜZELCE KUYULU'nun, Doç. Dr. Sibel SENAN danışmanlığında "Panoramik Diş Röntgenlerinden Diş Eksikliklerinin Makine Öğrenmesi Kullanılarak Tespiti ve Sınıflandırılması" başlıklı tez çalışması ile ilgili verileri T.C Sağlık Bilimleri Üniversitesi Hamidiye Diş Hekimliği Fakültesinden alabilmesi hususunda;

Bilgilerinizi ve gereğini arz ederim.

Prof. Dr. Serdar AYDIN
Enstitü Müdürü

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu :BS5S4JKNSZ Belge Takip Adresi : https://www.turkiye.gov.tr/istanbul-universitesi-cerrahpasa-ebys

Adres:İstanbul Üniversitesi-Cerrahpaşa Rektörlüğü, 34320 Avcılar-İstanbul
Telefon:0212 404 03 00 Faks:0212 404 07 01
Web:https://www.iuc.edu.tr
Kep Adresi:iuc@hs01.kep.tr
Bilgi için: Özgün BOYRAZ
Dahili: 0212 404 03 00

Bu belge,güvenli elektronik imza ile imzalanmıştır.

İÜC Tarih ve Sayı: 26.01.2024-898770

T.C.

Lisansüstü Eğitim Enstitüsü Müdürlüğü
Bilgisayar Mühendisliği Anabilim Dalı Başkanlığı

Sayı : E-15974368-399-898770 26.01.2024
Konu : Nurefşan GÜZELCE KUYULU Hk.

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Bilgisayar Mühendisliği Anabilim Dalı, Tezli Yüksek Lisans Programı'na 4801220055 numara ile kayıtlı Nurefşan GÜZELCE KUYULU'nun, Doç. Dr. Sibel SENAN danışmanlığında "Panoramik Diş Röntgenlerinden Diş Eksikliklerinin Makine Öğrenmesi Kullanılarak Tespiti ve Sınıflandırılması" ile ilgili danışman uygun yazısı ekte sunulmuştur.

Bilgilerinize arz ederim.

Prof. Dr. Ahmet SERTBAŞ
Anabilim Dalı Başkanı

Ek:
1- Danışman Uygun Yazısı
2- Tez Adı Kabul Belgesi
3- Bilimsel Araştırma Başvuru Formu

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu :BSEPY5JCZ2 Belge Takip Adresi : https://www.turkiye.gov.tr/istanbul-universitesi-cerrahpasa-ebys

Adres:İstanbul Üniversitesi-Cerrahpaşa Rektörlüğü, 34320 Avcılar-İstanbul
Telefon:0212 404 03 00 Faks:0212 404 07 01
Web:İstanbul Üniversitesi-Cerrahpaşa Rektörlüğü, 34320 Avcılar-İstanbul
Kep Adresi:iuc@hs01.kep.tr

Bilgi için: Ahmet NALBANT
Dahili: 20604

Bu belge,güvenli elektronik imza ile imzalanmıştır.

İÜC Tarih ve Sayı: 15.11.2023-837142

T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
REKTÖRLÜĞÜ
Lisansüstü Eğitim Enstitüsü Müdürlüğü

Sayı : E-13022260-300-837142 15.11.2023
Konu : Nurefşan GÜZELCE KUYULU

DAĞITIM YERLERİNE

Lisansüstü Eğitim Enstitüsü Yönetim Kurulu'nun 15.11.2023 tarih ve 44 sayılı oturumunda alınan 1 numaralı karar aşağıda belirtilmiştir.

Gereğini rica ederim.

Karar 1. Bilgisayar Mühendisliği Anabilim Dalı, Tezli Yüksek Lisans Programı'na 4801220055 numara ile kayıtlı Nurefşan GÜZELCE KUYULU'nun, Doç. Dr. Sibel SENAN danışmanlığında "Panoramik Diş Röntgenlerinden Diş Eksikliklerinin Makine Öğrenmesi Kullanılarak Tespiti ve Sınıflandırılması" [Detection and Classification of Dental Deficiencies from Panoramic Dental X-rays Using Machine Learning] teklif edilen tez adı ve konusu öneri formu hakkında Anabilim Dalı Başkanlığı'ndan gelen 06.11.2023 tarih ve 829824 sayılı yazı görüşüldü; Tez adının "Panoramik Diş Röntgenlerinden Diş Eksikliklerinin Makine Öğrenmesi Kullanılarak Tespiti ve Sınıflandırılması" [Detection and Classification of Dental Deficiencies from Panoramic Dental X-Rays Using Machine Learning] şeklinde kabulüne oybirliğiyle karar verildi.

Prof. Dr. Serdar AYDIN
Enstitü Müdürü

DAĞITIM:
Gereği:
Bilgisayar Mühendisliği Anabilim Dalı Başkanlığına

Bilgi:
Sayın Doç. Dr. Sibel SENAN

Bu belge, güvenli elektronik imza ile imzalanmıştır.
Belge Doğrulama Kodu :BSDPF4YZZZ Belge Takip Adresi : https://www.turkiye.gov.tr/istanbul-universitesi-cerrahpasa-ebys
Adres:İstanbul Üniversitesi-Cerrahpaşa Rektörlüğü, 34320 Avcılar-İstanbul
Telefon:0212 404 03 00 Faks:0212 404 07 01
Web:https://www.iuc.edu.tr
Kep Adresi:iuc@hs01.kep.tr
Bilgi için: Gülay EREN
Dahili: 53062
Bu belge,güvenli elektronik imza ile imzalanmıştır.
Bu belge,güvenli elektronik imza ile imzalanmıştır.

Tarih ve Sayı: 26.02.2024-926579

T.C.
SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
Hamidiye Diş Hekimliği Fakültesi Dekanlığı

Sayı : E-36960053-300-334478 26.02.2024
Konu : Tez Çalışma İzni Hk.

İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA REKTÖRLÜĞÜNE
Üniversite Mahallesi Bağlariçi Caddesi No:7 AVCILAR/İSTANBUL

İlgi : 19.02.2024 tarihli ve 917992 sayılı yazınız,

Üniversiteniz Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalında görevli Doç. Dr. Sibel SENAN'ın danışmanlığında tezli yüksek lisans eğitimine devam eden Nurefşan GÜZELCE KUYULU'nun "Panoramik Diş Röntgenlerinden Diş Eksikliklerinin Makine Öğrenmesi Kullanılarak Tespiti ve Sınıflandırılması" başlıklı tez çalışması kapsamında talep edilen panoramik diş röntgeni görüntü verilerinin kulllanım izninin Sağlık Bakanlığı ile Üniversitemiz Rektörlüğü arasında imzalanan birlikte kullanım protokolü gereği İstanbul Tacirler Eğitim Vakfı Sultanbeyli Ağız ve Diş Sağlığı Eğitim ve Araştırma Hastanesinden alınması gerekmektedir.

Bilgilerinizi ve gereğini arz ederim.

Prof. Dr. Yunus KARAKOÇ
Rektör a.
Rektör Yardımcısı

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu :*BS5L4EFMVE* Pin Kodu :33682 Belge Takip Adresi : https://www.turkiye.gov.tr/sbu-ebys?eD=BS5L4EFMVE&eS=334478

Adres:Mekteb-i Tıbbiyye-i Şâhâne Külliyesi, Tıbbiye Cad. No: 38 Selimiye - Üsküdar, İSTANBUL
Telefon:02167778806 Faks:216 346 36 40
Web:http://sbu.edu.tr
Kep Adresi:sbu@hs01.kep.tr
Bilgi için: Yasemin ÜSTÜN
Ünvanı: Memur