



MÜHENDİSLİK VE DOĞA BİLİMLERİ FAKÜLTESİ
BİLGİSAYAR MÜHENDİSLİĞİ BÖLÜMÜ
BİTİRME PROJESİ TEZİ

Menengioma Beyin Tümörü Görüntüleri Üzerinden Grade Tahmini
(Grade Prediction on Meningioma Brain Tumor Images)

21120205037 Talha KARAHAN

21120205059 Kaan GÜMELE

DANIŞMAN

Dr. Öğretim Üyesi Muhammet Sinan BAŞARSLAN

Haziran, 2025

İstanbul Medeniyet Üniversitesi, İstanbul

ÖNSÖZ

Bu bitirme projesi, İstanbul Medeniyet Üniversitesi Bilgisayar Mühendisliği Bölümü kapsamında, 2024-2025 eğitim öğretim yılı bahar döneminde gerçekleştirilmiştir. Proje sürecinde ekip olarak görev paylaşımı yapılmış, Kaan GÜMELE yapay zeka modeli geliştirme ve model entegrasyonunu üstlenmiş; Talha KARAHAN ise sistem arayüzü, dosya işleme modülleri ve kullanıcı deneyimi kısmında çalışmıştır.

Danışmanımız Dr. Öğretim Üyesi Muhammed Sinan BAŞARSLAN'a değerli katkı ve yönlendirmeleri için teşekkür ederiz. Ayrıca proje sürecinde açık kaynak kodlu kütüphaneler, çevrimiçi eğitim materyalleri ve araştırma makalelerinden faydalanılmıştır.

İÇİNDEKİLER

ÖNSÖZ	2
İÇİNDEKİLER.....	3
TABLO LİSTESİ.....	7
ŞEKİL LİSTESİ	8
ÖZET	9
ABSTRACT	10
1.GİRİŞ.....	11
1.1 KONUNUN ÖNEMİ.....	11
1.2 ÇALIŞMANIN AMACI.....	11
1.3 ÖZGÜN DEĞER.....	11
1.4 HİPOTEZ VE ARAŞTIRMA SORUSU.....	12
2.GENEL BAKIŞ.....	13
2.1 LİTERATÜRDEKİ ÇALIŞMALAR VE KLİNİK ÖNEM.....	13
2.2 LİTERATÜR TARAMASI VE MEVCUT YAKLAŞIMLAR.....	13
2.3 Klinik Uygulamalar ve Yapay Zekâ Entegrasyonu.....	13
3.MATERYAL VE YÖNTEM	14
3.1 Kullanılan Teknolojiler	14
3.1.1 Backend Teknolojileri	14
3.1.1.1 Python 3.12.....	14
3.1.1.2 FastAPI.....	14
3.1.1.3 TensorFlow & Keras	14
3.1.1.4 NumPy.....	14
3.1.1.5 Pydicom.....	14
3.1.1.7 Pydantic	15
3.1.1.8 Uvicorn	15
3.1.1.9 Git.....	15
3.1.2 Frontend Teknolojileri.....	15
3.1.2.1 React.....	15
3.1.2.2 TypeScript	15
3.1.2.3 Chakra UI	15
3.1.2.4 Axios.....	15
3.1.2.5 React Dropzone	16

3.1.2.6 React Hook Form & Yup	16
3.1.2.7 React Toastify	16
3.1.2.8 html2canvas & jsPDF	16
3.1.2.9 React Router	16
3.1.2.10 React Query (TanStack Query)	16
3.1.2.11 Zustand	16
3.1.2.12 React Helmet	16
3.1.2.13 React Icons	17
3.1.2.14 React Suspense, Lazy & Memo	17
3.1.2.15. React Context API	17
3.2 Veri Seti ve Özellikleri	17
3.3 Sinir Ağları Mimarileri ve Eğitim Süreci	19
3.3.1 Yapay Sinir Ağları	19
3.3.1.1 Perceptron	19
3.3.1.2 Çok Katmanlı Algılayıcılar (MLP)	19
3.3.2 Aktivasyon Fonksiyonları	19
3.3.2.1 Sigmoid Fonksiyonu	20
3.3.2.2 Tanh (Hiperbolik Tanjant)	20
3.3.2.3 ReLU (Rectified Linear Unit)	20
3.3.3 Derin Öğrenme ve Evrişimli Sinir Ağları (CNN)	20
3.3.3.1 Evrişim Katmanları	21
3.3.3.2 Havuzlama Katmanları	21
3.3.3.3 Tam Bağlantılı Katmanlar	21
3.3.4 Optimizasyon Algoritmaları	21
3.3.4.1 Gradient Descent	21
3.3.4.2 Adam (Adaptive Moment Estimation)	22
3.3.5 Eğitim Stratejileri	22
3.3.5.1 EarlyStopping, ReduceLRonPlateau	22
3.3.5.2 ModelCheckpoint	22
3.3.6 Overfitting	23
3.3.6.1 Dropout	23
3.4 Model Mimarisi ve Eğitim Süreci	23
3.4.1 Kullanılan Modeller	23
3.4.1.1 Xception	23
3.4.1.2 ResNet50	24
3.4.1.3 InceptionV3	25
3.4.1.4 DenseNet121	25

3.4.1.5 MobileNetV2	25
3.4.1.6 EfficientNetB0.....	26
3.4.2 Değerlendirme Metrikleri ve Yöntemleri	26
3.4.2.1 Confusion Matrix (Karmaşıklık Matrisi).....	26
3.4.2.2 Doğruluk (Accuracy).....	26
3.4.2.3 Kesinlik (Precision)	27
3.4.2.4 Duyarlılık (Recall / Sensitivity).....	27
3.4.2.5 F1 Skoru	27
3.4.2.6 ROC-AUC	27
3.4.2.7 Eğitim Kaybı	27
3.4.2.8 Doğrulama Kaybı	27
3.4.2.9 Eğitim ve Doğrulama Eğrileri	28
3.5 Sistem Mimarisi.....	28
3.5.1 Frontend.....	28
3.5.1.1 Yüklenen DICOM Dosyalarının Liste Görünümü	28
3.5.1.2 Dosya Yükleme Arayüzü (Sürükle, Bırak ve Seçim Destekli)	29
3.5.1.3 Model Tahmin Sonucu ve Güven Skoru Arayüzü	29
3.5.1.4 Yapay Zekâ Analiz Sonuçlarının PDF Formatında Dışa Aktarımı	30
3.5.1.5 Geçersiz Dosya Yükleme Durumunda Anlık Uyarı Mesajı	30
3.5.1.6 Yapay Zekâ Tabanlı MRI Analiz Raporu Arayüzü.....	31
3.5.2 Backend (Sunucu Uygulaması)	32
3.5.2.1 DICOM Görüntü İşleme ve Doğrulama Süreci.....	32
3.5.2.2 Yapay Zekâ Modeli Entegrasyonu ve Tahmin Süreci.....	32
3.5.2.3 Hata Yönetimi ve Loglama Sistemi	32
3.5.2.4 Medikal Görüntüleme API Uç Noktaları.....	33
3.5.2.5 AIAnalysis Yanıt Modeli Şeması	33
3.5.2.6 SampleMetrics Yanıt Modeli Şeması.....	34
3.5.2.7 ProcessingResult Yanıt Modeli Şeması.....	34
3.5.2.7 FileInfo Görüntü Metadata Şeması	34
3.5.3 AI Katmanı (Model Entegrasyonu)	35
3.6 Ek Özellikler.....	35
3.6.1 Tema Desteği.....	35
3.6.2 Yeni Modül Geliştirme	35
4. BULGULAR	36
4.1 MODEL ÇIKTILARININ İNCELENMESİ	36
4.1.1 XCEPTION	36
4.1.2 RESNET 50	37

4.1.3 INCEPTION V3	39
4.1.4 DENSENET 121	40
4.1.5 MobileNet	42
4.1.6 EfficientNetB0.....	43
4.2 Tüm Modellerin Karşılaştırılmalı Sonuç Kısmı	45
5. TARTIŞMA VE SONUÇ	47
KAYNAKLAR.....	48
EKLER	51
EK 1	51

TABLO LİSTESİ

Tablo 3.1: Karışıklık Matrisi Gösterimi	26
Tablo 4.2: Xception Test Sonuçları	37
Tablo 4.3: ResNET50 Test Sonuçları.....	38
Tablo 4.4: InceptionV3 Test Sonuçları.....	39
Tablo 4.5: DenseNet121 Test Sonuçları.....	41
Tablo 4.6: MobileNet Test Sonuçları	43
Tablo 4.7: EfficientNetB0 Modeli Test Sonuçları.....	44
Tablo 4.8: Tüm Modellerin Sınıflandırma Test Sonuçlarının Karşılaştırılması.....	45

ŞEKİL LİSTESİ

Şekil 3.1: Sınıf Dağılım Grafiği.....	18
Şekil 3.2: Veri Ayrımı Pasta Grafiği.....	18
Şekil 3.3: Xception Mimarisi	24
Şekil 3.4: ResNet Mimarisi	24
Şekil 3.5: DenseNet Yapısı	25
Şekil 3.6: Yükleme Ekranı	28
Şekil 3.7: Dosya Yükleme Arayüzü.....	29
Şekil 3.8: Model Tahmin Sonucu Ekranı.....	29
Şekil 3.10: Uyarı Mesajına Örnek.....	30
Şekil 3.11: MRI Analiz Raporu Arayüzü.....	31
Şekil 3.12: Medikal Görüntüleme API.....	33
Şekil 3.13: AIAnalysis Yanıt Modeli Şeması	33
Şekil 3.14: SampleMetrics API Modeli	34
Şekil 3.15: ProcessingResult API Modeli	34
Şekil 3.16: FileInfo API Modeli	34

ÖZET

Meningiomlar, merkezi sinir sistemi tümörlerinin önemli bir alt grubunu oluşturmaktadır olup, Dünya Sağlık Örgütü (WHO) tarafından Grade I (iyi huylu), Grade II (atipik) ve Grade III (kötü huylu) olmak üzere üç ana kategoriye ayrılmaktadır. Bu sınıflandırma, hasta prognozu ve tedavi planlamasında belirleyici bir rol oynamaktadır. Mevcut klinik uygulamalarda meningiomların grade seviyesinin belirlenmesi, genellikle cerrahi müdahale ve histopatolojik inceleme yoluyla gerçekleştirilmektedir. Ancak bu süreç hem zaman alıcı hem de invaziv nitelikte olup, hasta açısından ek risk ve maliyet oluşturmaktadır.

Bu çalışma, manyetik rezonans görüntüleme (MRI) verilerinden yararlanarak, meningiomların grade seviyesini non-invaziv şekilde tahmin eden bir derin öğrenme tabanlı karar destek sistemi geliştirmeyi amaçlamaktadır. Model, Convolutional Neural Network (CNN) mimarisi üzerine inşa edilmiş olup, MRI görüntüleri uygun ön işleme ve veri artırma (data augmentation) tekniklerine tabi tutularak modele giriş olarak sunulmuştur. Modelin çıktısı, meningiomun WHO sınıflandırmasına göre tahmini grade seviyesini %95'in üzerinde doğrulukla belirlemektedir.

Proje kapsamında ayrıca geliştirilen web tabanlı kullanıcı arayüzü, doktorların sistemle kolayca etkileşime geçmesini ve analiz sonuçlarını anlık olarak görselleştirmesini sağlamaktadır. Bu sayede, klinik karar verme süreçleri hızlanmakta ve patolojik incelemelere olan bağımlılık önemli ölçüde azalmaktadır.

Çalışmanın özgün değeri, MRI görüntülerinden elde edilen bilgiler ile meningiom sınıflandırmasını cerrahi müdahale olmaksızın gerçekleştirebilen yapay zekâ destekli bir sistem sunmasıdır. Bu yaklaşım, tıbbi tanı süreçlerine hız kazandırmakta, hasta konforunu artırmakta ve sağlık sisteminde zaman ve kaynak verimliliğine katkı sağlamaktadır.

Anahtar Kelimeler: Meningioma, Manyetik Rezonans Görüntüleme, Yapay Zekâ, Derin Öğrenme, CNN, Non-İnvaziv Tanı, Grade Sınıflandırması, Web Tabanlı Karar Destek Sistemi

ABSTRACT

Meningiomas represent a significant subgroup of central nervous system tumors and are classified into three main grades by the World Health Organization (WHO): Grade I (benign), Grade II (atypical), and Grade III (malignant). This classification plays a critical role in determining the patient's prognosis and treatment strategy. In current clinical practice, the grading of meningiomas often requires surgical intervention and histopathological examination, which are invasive and time-consuming procedures.

This study aims to develop a non-invasive deep learning-based decision support system that can predict the grade of meningiomas using magnetic resonance imaging (MRI) data. The model is built upon a CNN architecture, and input MRI images are processed through proper preprocessing and data augmentation techniques before training. The output of the model is a grade prediction according to the WHO classification, with a target accuracy exceeding 95%.

Additionally, a web-based user interface was developed to enable clinicians to easily interact with the system and visualize prediction results in real-time. This integration significantly accelerates the diagnostic process and reduces dependence on pathological examinations.

The originality of this study lies in its ability to provide an AI-assisted grading system for meningiomas based solely on MRI images, without requiring surgical biopsy. This approach enhances diagnostic speed, improves patient comfort, and contributes to the efficiency of healthcare systems by saving time and resources.

Keywords: Meningioma, Magnetic Resonance Imaging, Artificial Intelligence, Deep Learning, CNN, Non-Invasive Diagnosis, Grade Classification, Web-Based Decision Support System

1.GİRİŞ

1.1 KONUNUN ÖNEMİ

Beyin tümörleri, insan sağlığı açısından ciddi sonuçlara yol açabilen ve hızlı müdahale gerektiren nörolojik hastalıkların başında gelmektedir. Bu tümörler arasında meningiomlar, merkezi sinir sistemi tümörlerinin yaklaşık %30'unu oluşturmakta ve sıklıkla erişkin popülasyonda görülmektedir. Dünya Sağlık Örgütü (WHO) tarafından meningiomlar üç farklı grade altında sınıflandırılmaktadır: Grade I (iyi huylu), Grade II (atipik) ve Grade III (kötü huylu/malign). Bu sınıflandırma, tümörün biyolojik davranışını, tedavi yöntemlerini ve hastanın prognozunu doğrudan etkilemektedir.[1]

Mevcut klinik uygulamalarda, meningiomun grade seviyesinin kesin olarak belirlenebilmesi için cerrahi biyopsi ve ardından patolojik inceleme gerekmektedir. Ancak bu süreç hem invazivdir hem de zaman açısından sınırlayıcıdır. Tanı sürecinde yaşanan gecikmeler, hastanın tedaviye geç başlatılmasıyla sonuçlanabilmekte, bu da özellikle Grade II ve III meningiomlar için hayati risk taşımaktadır. Bu bağlamda, non-invaziv yöntemlerle meningioma grade tayinini gerçekleştirmek büyük önem arz etmektedir.

1.2 ÇALIŞMANIN AMACI

Bu çalışmanın temel amacı, MRI verilerinden yararlanarak, meningiom tümörlerinin grade seviyesini non-invaziv bir şekilde tahmin edebilen bir yapay zekâ modelinin geliştirilmesidir. Derin öğrenme alanında yaygın olarak kullanılan CNN yapısı temel alınarak geliştirilen bu model, DICOM (Digital Imaging and Communications in Medicine) formatındaki MRI görüntülerini analiz ederek tümörün Tipik (Grade I) ya da Non-Tipik (Grade II ve Grade III) olup olmadığını belirleyebilecektir.

Modelin arka planında, transfer öğrenme yöntemiyle özelleştirilmiş Xception mimarisi kullanılmıştır. Modelin çıktısı olarak 0-1 arasında bir olasılık değeri üretilmekte ve belirlenen eşik değerine (threshold = 0.5) göre sınıflandırma yapılmaktadır. Bu sistem, yalnızca model çıktısıyla sınırlı kalmamakta; aynı zamanda kullanıcı dostu bir web arayüzüyle doktorların analiz sonuçlarını görselleştirerek yorumlayabilmesini de mümkün kılmaktadır.

1.3 ÖZGÜN DEĞER

Bu tez çalışması, klasik tanı yöntemlerinin gerektirdiği cerrahi ve patolojik süreçlerin yerine, yalnızca MRI görüntülerinden yola çıkarak grade tespiti yapabilen bir yapay zekâ sistemini ilk defa tam entegre web uygulaması ile birlikte sunması bakımından özgünlük taşımaktadır.

Literatürde benzer çalışmalar histopatolojik görüntülerle sınırlıyken, bu çalışma doğrudan MRI görüntüleri üzerinden sınıflandırma yapmasıyla fark yaratmaktadır.

Bu sayede hem hasta konforu artmakta hem de tanı süreci hızlandırılmaktadır. Elde edilen sonuçlar; klinik karar destek sistemlerine katkı sağlayabilecek nitelikte olup, sağlık teknolojileri alanında önemli bir adım niteliği taşımaktadır.

1.4 HİPOTEZ VE ARAŞTIRMA SORUSU

Bu araştırmanın temel hipotezi, derin öğrenme tabanlı bir modelin yalnızca MRI görüntülerinden yararlanarak meningiom tümörlerinin grade tahminini gerçekleştirebileceği, bu sayede patolojik doğrulamalara olan ihtiyacı azaltabileceği ve tanı sürecini klinik açıdan anlamlı bir doğrulukla hızlandırabileceği yönündedir. Bu bağlamda çalışmada şu sorulara yanıt aranmaktadır: MRI görüntüleri, meningiom grade sınıflandırması için yeterli bilgiyi barındırmakta mıdır? CNN tabanlı bir model ile %95'in üzerinde doğruluk elde etmek mümkün müdür? Ayrıca geliştirilen sistem, klinik uygulamalarda kullanılacak düzeyde bir hız, güvenilirlik ve esneklik sunmakta mıdır?

2.GENEL BAKIŞ

2.1 LİTERATÜRDEKİ ÇALIŞMALAR VE KLİNİK ÖNEM

Beyin tümörleri, merkezi sinir sisteminde görülen en yaygın hastalık gruplarından biridir. Özellikle meningiomlar, genellikle iyi huylu olmalarına rağmen, biyolojik davranışlarına göre farklı risk seviyeleri taşımaktadır. Dünya Sağlık Örgütü'nün sınıflamasına göre meningiomlar Grade I (typical), Grade II (non-typical) ve Grade III (non-typical) olarak üç temel gruba ayrılır. Bu sınıflandırma, hastanın tedavi planlaması ve takibi açısından kritik öneme sahiptir. Geleneksel olarak bu sınıflandırma patolojik inceleme ile yapılmakta, bu da cerrahi müdahale ve invaziv süreçleri zorunlu kılmaktadır.

Son yıllarda, tıbbi görüntüleme verilerine dayalı yapay zekâ destekli sınıflandırma modelleri bu süreci kolaylaştırmak ve hızlandırmak amacıyla geliştirilmektedir. Özellikle MRI görüntüleri, tümör dokusunun non-invaziv bir şekilde detaylı analizi için yüksek çözünürlük sağlamaktadır. Derin öğrenme mimarilerinin özellikle ResNet50, DenseNet gibi yapıların tıbbi görüntülerde yüksek doğruluk oranlarına ulaştığı çeşitli literatür çalışmalarında gösterilmiştir. Bu bağlamda geliştirilen sistemler, tanı süreçlerini kolaylaştırmakla kalmayıp, klinik karar destek sistemlerine de entegre edilerek sağlık profesyonellerine yardımcı olmaktadır.

2.2 LİTERATÜR TARAMASI VE MEVCUT YAKLAŞIMLAR

Literatürde meningiom sınıflandırması için çeşitli makine öğrenmesi ve derin öğrenme modelleri önerilmiştir. Bukhari ve arkadaşları, histopatolojik görüntüler üzerinden geliştirdikleri CNN modeli ile %98.3 F1 skoru elde etmişlerdir [2]. Banzato ise MRI verilerini kullanarak InceptionV3 CNN modeliyle %93.1 doğruluk oranı raporlamıştır [3]. Liu'nun Random Forest temelli modelinde %88 AUC değeri elde etmiştir [4]. Morais ise destek vektör makineleri ile %96.2 doğruluk oranına ulaşmıştır[5] Literatürde klinik, radyomik ve derin transfer öğrenme (DTL) özelliklerinin birlikte kullanıldığı bir çalışmada, DTLR nomogram modeli test verisinde %86.6 AUC, %80.4 doğruluk ve %86.3 özgüllük ile en yüksek performansı göstermiştir; DeLong testi sonuçlarına göre yalnızca radyomik modelin yeterli olduğu belirtilmiş ve DTL özelliklerinin modele katkısının sınırlı olduğu ifade edilmiştir [6]. Tüm bu çalışmalar, görüntü verileri üzerinden meningiomların grade sınıflandırmasının mümkün olduğunu ve yüksek başarı oranlarıyla gerçekleştirilebileceğini ortaya koymaktadır.

2.3 KLİNİK UYGULAMALAR VE YAPAY ZEKÂ ENTEGRASYONU

Yapay zekâ modellerinin klinik karar destek sistemlerine entegrasyonu, doktorların zaman kazanmasını ve tanı koyma süreçlerinde güvenilir kararlar almasını sağlayabilir. Bu projede geliştirilen sistem, MRI görüntüsünden elde edilen verileri yapay zekâ tabanlı bir modelle analiz ederek, doktorun elindeki veriye dayalı olarak hızlı ve güvenilir bir değerlendirme sunar. Ayrıca modelin tahmin çıktıları kullanıcı arayüzünde görsel ve metin formatında sunulularak karar sürecine şeffaflık kazandırılır.

3.MATERYAL VE YÖNTEM

3.1 KULLANILAN TEKNOLOJİLER

Bu proje kapsamında geliştirilen sistem, tıbbi görüntülerin yapay zekâ destekli analizini gerçekleştiren ve kullanıcı dostu bir arayüz ile bu analizi sunan kapsamlı bir web tabanlı karar destek sistemidir. Sistem mimarisi; istemci tarafı (frontend), sunucu tarafı (backend) ve derin öğrenme tabanlı modellerden oluşan üç temel yapı üzerine inşa edilmiştir. Her katmanda, görevine en uygun teknoloji ve araçlar tercih edilmiştir. Aşağıda, kullanılan başlıca teknolojiler, işlevsel rollerine göre detaylı şekilde açıklanmıştır.

3.1.1 Backend Teknolojileri

Backend mimarisi, veri işleme, yapay zekâ modeli entegrasyonu, API sunumu ve sistemin genel performansını sağlamak amacıyla oluşturulmuştur. Kullanılan teknolojiler ve işlevleri aşağıda açıklanmıştır:

3.1.1.1 Python 3.12

Sunucu tarafındaki tüm işlemler Python dili ile geliştirilmiştir. Python'un bilimsel kütüphaneler ve derin öğrenme ekosistemindeki güçlü yeri, bu proje için esnek ve güçlü bir altyapı sunmuştur[7].

3.1.1.2 FastAPI

Modern, hızlı ve asenkron bir Python web framework'ü olan FastAPI ile tüm RESTful API endpoint'leri geliştirilmiştir. FastAPI'nin otomatik Swagger/OpenAPI dokümantasyon desteği, hem geliştiricilere hem de kullanıcıya kullanım kolaylığı sağlamıştır. Ayrıca tip güvenliği, yüksek performans ve async destekli mimarisi ile tercih edilmiştir[8].

3.1.1.3 TensorFlow & Keras

Derin öğrenme modellerinin eğitimi ve dağıtımı için kullanılmıştır. ResNet50 mimarisi, Keras ile yapılandırılmış, eğitim süreci tamamlandıktan sonra TensorFlow ile servislenmiştir. Eğitilen model '.keras'formatında kaydedilmiş ve her analiz çağrısında hızlı tahmin sağlayacak şekilde entegre edilmiştir [9][10].

3.1.1.4 NumPy

Sayısal hesaplamalar, görüntülerin yeniden boyutlandırılması ve normalizasyonu gibi işlemler için kullanılmıştır. Ayrıca model çıktılarına ait istatistiksel verilerin işlenmesinde de önemli rol oynamıştır.

3.1.1.5 Pydicom

DICOM formatlı tıbbi görüntülerin içeriğini (piksel verisi, hasta bilgisi, görüntü tarihi gibi metadata) okumak ve işlemek için tercih edilmiştir. Bu sayede, analizde yalnızca görüntü değil, ilgili klinik bilgiler de sisteme entegre edilebilmiştir. [11]

3.1.1.7 Pydantic

API istek ve yanıtlarındaki verilerin şema doğrulamasını ve serileştirilmesini sağlamıştır. Bu sayede sistem, dışardan gelen verilerdeki hataları daha hızlı fark etmiş ve veri bütünlüğü sağlanmıştır.

3.1.1.8 Uvicorn

FastAPI uygulamasını çalıştırmak için kullanılan ASGI sunucusudur. Yüksek performanslı, hafif ve asenkron yapısı sayesinde API sunumu hızlı ve güvenilir hale gelmiştir[12].

3.1.1.9 Git

Versiyon kontrolü ve işbirlikçi yazılım geliştirme süreçlerinde kullanılmıştır. Kod değişikliklerinin takibi, iş bölümü ve proje yönetimi Git ile etkin biçimde yürütülmüştür[13].

3.1.2 Frontend Teknolojileri

Frontend yapısı, kullanıcıyla etkileşimli, duyarlı (responsive), modern ve yüksek performanslı bir deneyim sunmak üzere tasarlanmıştır. Kullanılan teknolojiler ve bu teknolojilerin projeye katkıları aşağıda detaylı şekilde sunulmuştur.

3.1.2.1 React

React, kullanıcı arayüzleri geliştirmek için kullanılan, bileşen tabanlı ve açık kaynak kodlu bir JavaScript kütüphanesidir. Facebook tarafından geliştirilen bu yapı, tek sayfa uygulamalar (SPA) oluşturmada yaygın olarak tercih edilmektedir. React ile arayüzler; yeniden kullanılabilir, modüler ve dinamik bileşenler şeklinde inşa edilir. Bu projede tüm kullanıcı arayüzü bileşenleri React ile geliştirilmiştir. Bu sayede arayüzlerin yönetimi kolaylaştırılmış ve kullanıcı deneyimi artırılmıştır[14].

3.1.2.2 TypeScript

TypeScript, JavaScript'in tip güvenliği sağlayan bir üst kümesidir. Tüm '*.tsx' ve '*.ts' dosyalarında kullanılmış; değişken, fonksiyon ve API verileri için tanımlamalar yapılmıştır. Böylece hem geliştirme sürecinde hata oranı düşürülmüş hem de kodun okunabilirliği ve sürdürülebilirliği artırılmıştır[15].

3.1.2.3 Chakra UI

Chakra UI, erişilebilir ve özelleştirilebilir bileşenler sunan modern bir UI kütüphanesidir. Tüm arayüz bileşenlerinde kullanılmış; responsive ve şık bir tasarım elde edilmiştir. Tema desteği sayesinde karanlık mod gibi özellikler kolayca uygulanabilmiştir [16].

3.1.2.4 Axios

HTTP isteklerinin gerçekleştirilmesi için kullanılan bu kütüphanedir. Backend API ile haberleşmede görev almıştır. Özellikle dosya yükleme ve analiz sonucu alma işlemlerinde kullanılmıştır[17].

3.1.2.5 React Dropzone

React Dropzone, dosya sürükle-bırak (drag & drop) özelliği sunan bir kütüphanedir. Bu projede, kullanıcıların bir veya birden fazla DICOM dosyasını sürükleyerek veya manuel olarak seçerek yükleyebileceği etkileşimli alanlar oluşturmak için kullanılmıştır. Böylece dosya yükleme işlemi daha kullanıcı dostu ve hızlı hale getirilmiştir.

3.1.2.6 React Hook Form & Yup

Form yönetimini kolaylaştırmak ve validasyon kuralları ile veri girişlerini denetlemek amacıyla React Hook Form ve Yup birlikte kullanılmıştır. Bu projede, kullanıcıların yüklediği dosyaların geçerliliği Yup şemalarıyla doğrulanmış, hatalı girişler React Hook Form ile kontrol altına alınarak kullanıcıya anlık bildirimler sunulmuştur.

3.1.2.7 React Toastify

React Toastify, uygulamada anlık bildirimleri kullanıcıya göstermek için kullanılmıştır. Bu projede, başarılı dosya yükleme, analiz işleminin tamamlanması veya oluşan hatalar gibi durumlar kullanıcıya ekranın üst köşesinde gösterilen uyarı kutucuklarıyla bildirilmiştir.

3.1.2.8 html2canvas & jsPDF

html2canvas, kullanıcı arayüzündeki bir bileşenin ekran görüntüsünü alırken, jsPDF bu görüntüyü PDF formatına dönüştürmekte kullanılmıştır. Bu projede, analiz sonuçlarının ekran görüntüsü alınarak PDF'e çevrilmesi ve bu çıktının kullanıcının cihazına indirilmesi sağlanmıştır.

3.1.2.9 React Router

React Router, tek sayfa uygulamalarda sayfa geçişlerini yönetmek için kullanılan bir yönlendirme kütüphanesidir. Bu projede spine, brain ve ana sayfa gibi farklı ekranlara geçişlerin sağlanmasında etkin olarak kullanılmıştır.

3.1.2.10 React Query (TanStack Query)

React Query, API verilerinin önbelleğe alınması ve yönetilmesi için kullanılır. Projede, analiz işlemlerinden gelen sonuçlar gibi sık güncellenen veriler React Query ile kontrol edilerek performans artırılmış ve gereksiz veri istekleri azaltılmıştır.

3.1.2.11 Zustand

Zustand, basit ve hafif bir global durum yönetim kütüphanesidir. Bu projede, analiz sonuçları, dosya yükleme durumu ve kullanıcı ayarları gibi uygulama genelindeki veriler Zustand ile yönetilmiş ve bileşenler arasında paylaşılmıştır [18].

3.1.2.12 React Helmet

React Helmet, her sayfa için dinamik olarak başlık ve meta etiketleri tanımlanmasını sağlar. Bu projede, farklı sayfaların başlıkları ve açıklamaları SEO uyumlu olacak şekilde Helmet ile yapılandırılmıştır.

3.1.2.13 React Icons

React Icons, uygulamada ikon kullanımını kolaylaştıran bir kütüphanedir. Bu projede, kullanıcıya sunulan arayüzlerde simgelerin daha anlaşılır ve estetik görünmesini sağlamak amacıyla tercih edilmiştir.

3.1.2.14 React Suspense, Lazy & Memo

React Suspense, yüklenmekte olan bileşenler için bekleme ekranı oluştururken; React Lazy, bileşenlerin sadece ihtiyaç anında yüklenmesini sağlar. React Memo ise gereksiz yeniden render işlemlerini önler. Bu projede, performans optimizasyonu amacıyla bu üç özellik birlikte kullanılmıştır.

3.1.2.15. React Context API

Context API, prop drilling olmadan bileşenler arasında veri paylaşımı sağlar. Bu projede tema tercihi, dil seçimi ve kullanıcı durumu gibi global verilerin yönetilmesi amacıyla Context API'den faydalanılmıştır.

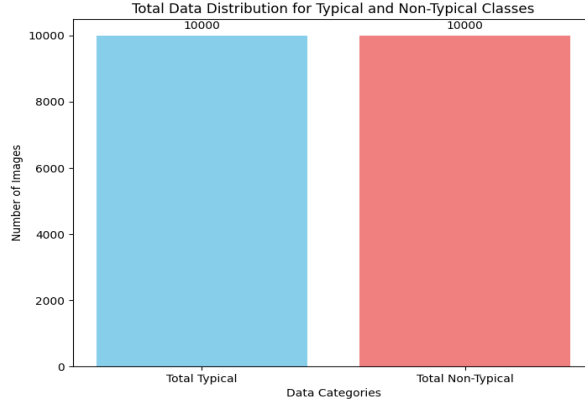
3.2 VERİ SETİ VE ÖZELLİKLERİ

Bu çalışmada yapay zekâ modelinin eğitimi için kullanılan veri seti, toplamda 20.000 adet medikal görüntüden oluşmaktadır. Tüm görüntüler DICOM formatında olup, bu durum sistemin doğrudan medikal standartlara uygun şekilde çalışmasını sağlamaktadır. Veri kümesinde, 'Tipik Tümör' ve 'Non-Tipik Tümör' olmak üzere iki sınıf yer almakta ve her sınıf 10.000 görüntü ile eşit sayıda temsil edilmektedir. Böylece sınıf dengesizliği kaynaklı öğrenme hatalarının önüne geçilmiş ve modelin adil sınıflandırma yapabilme yeteneği desteklenmiştir.

Çalışmada kullanılan bu görüntüler, hazır internet veri setlerinden değil; İstanbul Ümraniye Eğitim ve Araştırma Hastanesi'nde görev yapan hekimler tarafından bizzat toplanmıştır. Veriler, klinik süreç içerisinde tanı amaçlı olarak görüntüleme yapılmış toplam 200 hastadan elde edilmiştir. Her bir hasta için ortalama 10 adet DICOM formatında MRI görüntüsü seçilerek yapay zekâ modeline uygun bir veri havuzu oluşturulmuştur. Böylelikle çalışmada etik onaylı, gerçek hastalara ait ve klinik bağlamı güçlü bir veri altyapısı kullanılmıştır.

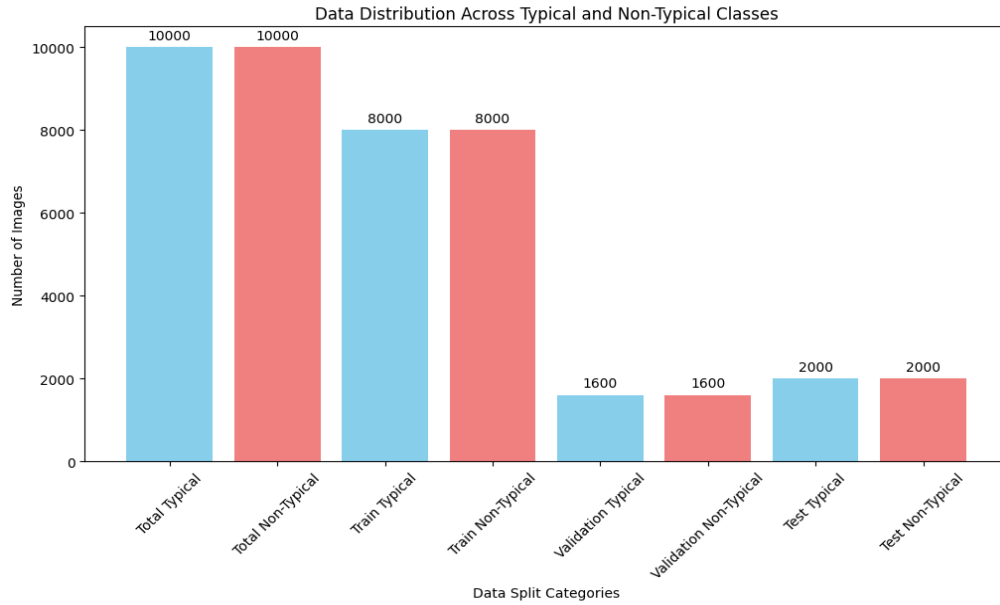
Veri seti, modelin daha sağlıklı bir şekilde genelleme yapabilmesini sağlamak amacıyla üç gruba ayrılmıştır. Görüntülerin %80'i (16.000 adet) modelin eğitimi için, %20'si (4.000 adet) ise test süreci için kullanılmıştır. Ayrıca eğitim verilerinin içerisinde %20 oranında (3.200 adet) görüntü, doğrulama işlemlerinde kullanılmıştır. Bu yapı sayesinde modelin eğitim sürecinde overfitting riski azaltılmış ve hiperparametre ayarlamaları daha güvenilir bir şekilde yapılabilmektedir.

Tüm görüntüler, derin öğrenme mimarisine uygun hale getirilmek üzere 224x224 piksel boyutlarına normalize edilmiştir. Çalışmada tek kanal olarak işlenmiş ve (224, 224, 1) şeklinde model girişine uygun hale getirilmiştir. Bu yaklaşım, modelin işlem yükünü azaltmakta ve eğitim süresini optimize etmektedir. Veri setinin yapısı, dağılımı ve ön işleme aşamaları, geliştirilen modelin sağlam, güvenilir ve tekrarlanabilir sonuçlar üretebilmesine olanak tanımaktadır.



Şekil 3.1: Sınıf Dağılım Grafiği

Şekil 1’de gösterildiği üzere 20.000 adet dıcom görüntü bulunmaktadır. Bunların 10.000 tanesi typical 10.000 tanesi non-typicaldir.



Şekil 3.2: Veri Ayrımı Pasta Grafiği

Şekil 2’de test, train ve validation için sınıflara ait gösterimi yapılmıştır. Model eğitimi için veri seti %80-%20 şeklinde ayrılmış olup daha sonrasında validation için eğitim kümesinin içerisinde de %20 şeklinde ayrılmıştır.

3.3 SİNİR AĞLARI MİMARİLERİ VE EĞİTİM SÜRECİ

Bu bölümde, kullanılan modellerin teorik olarak arka planını ve temeli detaylıca açıklanmıştır.

3.3.1 Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beynindeki nöronların çalışma prensiplerinden esinlenerek geliştirilmiş, öğrenme ve genelleme kabiliyetine sahip hesaplama modelleridir. Bu ağlar, özellikle büyük veri kümeleri üzerinde karmaşık ilişkileri modelleme ve çıkarım yapma yetenekleriyle öne çıkmaktadır.[19] YSA'ların temel amacı, girdiler ile çıktılar arasındaki doğrusal olmayan ilişkileri öğrenerek karar verme süreçlerini otomatikleştirmektir.

Bir yapay sinir ağı, genellikle girdi katmanı , bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur. Bu katmanlar arasındaki bağlantılar, öğrenme sürecinde güncellenen ağırlıklar ile tanımlanır. Her bir yapay nöron, kendisine gelen ağırlıklı girdileri toplar ve bir aktivasyon fonksiyonu aracılığıyla işleyerek bir çıktı üretir. Bu çıktı, bir sonraki katmana aktarılır ve böylece ileri beslemeli bir süreç gerçekleşir.

3.3.1.1 Perceptron

YSA'ların tarihsel gelişimi, perceptron modeli ile başlamıştır. Rosenblatt tarafından geliştirilen perceptron, basit bir doğrusal sınıflandırıcıdır ve yalnızca doğrusal olarak ayrılabilir veri kümelerinde etkili sonuçlar verebilmektedir [20]. Perceptron modelinde, her giriş x_i bir ağırlık w_i ile çarpılarak toplanır ve bu toplam, bir eşik değerine göre sınıflandırılır. Matematiksel olarak, perceptron çıktısı denklem 1'de verilmiştir.

$$y = f(\sum_{i=1}^n w_i x_i + b) \quad (1)$$

Burada 'f' genellikle bir eşik fonksiyonudur ve 'b' bias terimini temsil eder. Perceptron modeli, sınırlı kapasitesine rağmen yapay sinir ağlarının temel yapı taşını oluşturmuş ve daha karmaşık mimarilerin gelişimine zemin hazırlamıştır.[21]

3.3.1.2 Çok Katmanlı Algılayıcılar (MLP)

Tek katmanlı perceptronların doğrusal olmayan problemleri çözmemesi nedeniyle, çok katmanlı algılayıcılar geliştirilmiştir. MLP'ler, gizli katmanlar aracılığıyla doğrusal olmayan karar sınırları öğrenebilir. Bu mimaride her katmandaki nöronlar, bir önceki katmandan gelen bilgileri alır ve doğrusal olmayan aktivasyon fonksiyonları aracılığıyla işler. Bu sayede, daha karmaşık görevlerde yüksek başarı sağlanabilir [22].

YSA'ların öğrenme süreci, geriye yayılım algoritması ve optimizasyon teknikleri ile gerçekleştirilir. Geriye yayılım, modelin çıktısı ile gerçek değer arasındaki hata miktarını hesaplayarak bu hatayı ağırlık parametrelerine geri dağıtır ve ağırlıklar güncellenir. Bu süreç, hata fonksiyonunun türevleri alınarak, zincir kuralı ile uygulanır.

3.3.2 Aktivasyon Fonksiyonları

Yapay sinir ağlarının en önemli bileşenlerinden biri olan aktivasyon fonksiyonları, her bir nöronun çıktısını belirlerken doğrusal olmayanlık kazandıran matematiksel işlemlerdir. Aktivasyon fonksiyonu olmadan, ağın katmanları arasında sadece doğrusal dönüşümler yapılabilir ve bu da çok katmanlı yapının tek katmanlı bir lineer modelle aynı kapasiteye sahip

olması anlamına gelir [23]. Bu nedenle, aktivasyon fonksiyonları sinir ağlarının evrensel yaklaşılayıcı olmasını sağlayan temel bileşenlerdir.[24]

Sinir ağlarında kullanılan aktivasyon fonksiyonları, hem doğrusal olmayanlık hem de türevlenebilirlik özellikleriyle dikkat çeker. Bu özellikler, özellikle geri yayılım (backpropagation) algoritmasında türev hesaplamaları açısından kritik öneme sahiptir. Aşağıda en sık kullanılan aktivasyon fonksiyonlarına ve özelliklerine değinilmektedir.

3.3.2.1 Sigmoid Fonksiyonu

Sigmoid fonksiyonu, girdiyi $[0, 1]$ aralığına sıkıştırır S-şeklinde bir eğridir. Genellikle ikili sınıflandırma problemlerinin çıktı katmanlarında kullanılır. Matematiksel formülü denklem 2’de verilmiştir.

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (2)$$

Sigmoid fonksiyonu, çıktıyı olasılık yorumu yapılabilecek şekilde dönüştürür. Ancak, özellikle derin ağlarda gradyanların çok küçük değerlere ulaşması vanishing gradient sorununa neden olabilir[25].

3.3.2.2 Tanh (Hiperbolik Tanjant)

Tanh fonksiyonu da sigmoid gibi S-şeklinde ancak çıktıyı $[-1, 1]$ aralığına sıkıştırır. Bu, sıfır merkezli olması nedeniyle sigmoid'e göre daha avantajlıdır. Fonksiyon denklem 3’de tanımlanmıştır.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

Ancak tanh fonksiyonu da büyük mutlak girişlerde türevleri sıfıra yakınladığı için vanishing gradient problemine yatkındır.

3.3.2.3 ReLU (Rectified Linear Unit)

Son yıllarda en çok tercih edilen aktivasyon fonksiyonlarından biri ReLU’dur. Giriş negatifse sıfır, pozitifse kendisi olarak geçiren bu fonksiyon, hesaplama açısından da oldukça verimlidir. Denklem 4’te Relu aktivasyon fonksiyonu verilmiştir.

$$f(x) = \max(0, x) \quad (4)$$

ReLU, derin ağların eğitilmesini kolaylaştırır ve gradyanların yok olma problemini büyük ölçüde azaltır [26]. Ancak, negatif değerlerde türevin sıfır olması bazı nöronların hiç aktif olmamasına yol açabilir.

3.3.3 Derin Öğrenme ve Evrişimli Sinir Ağları (CNN)

Derin öğrenme, çok katmanlı yapay sinir ağı mimarileri aracılığıyla veri içerisindeki yüksek düzeyde soyut temsilleri öğrenmeye olanak tanıyan bir makine öğrenmesi yaklaşımıdır. Bu yöntem, özellikle büyük miktarda etiketli veri ve yüksek hesaplama gücü gerektirmekle birlikte, karmaşık örüntülerin otomatik olarak çıkarılmasını mümkün kılarak birçok alanda çığır açıcı sonuçlar üretmiştir [19]. Derin öğrenme mimarileri, biyolojik sinir sisteminden esinlenerek

geliştirilen katmanlı yapılar aracılığıyla doğrusal olmayan dönüşümleri ardışık biçimde uygulayarak, verinin temsilini her katmanda daha soyut ve ayrıştırılabilir hale getirir.

Bu bağlamda, CNN'ler özellikle görüntü işleme alanında derin öğrenme tekniklerinin en yaygın ve başarılı örneklerinden biri olarak öne çıkmaktadır. Evrişimsel sinir ağları, giriş görüntüleri üzerinde uzamsal hiyerarşiyi dikkate alan ve lokal ilişkileri modelleyebilen yapılar olup, geleneksel tam bağlantılı yapılardan farklı olarak parametre paylaşımı ve yerel alıcılık alanları prensipleri üzerine kuruludur. [27][28]

3.3.3.1 Evrişim Katmanları

Evrişim katmanları, giriş verisi üzerinde belirli bir boyuttaki çekirdek veya filtre ile kayan pencere mantığıyla konvolüsyon işlemi gerçekleştirerek öznitelik haritaları üretir. Bu öznitelik haritaları, kenar, doku, şekil gibi düşük seviyeli özelliklerden başlayarak, ağırlı derinliğine bağlı olarak daha soyut ve yüksek seviyeli temsillere dönüşür. Her filtre, öğrenilebilir ağırlıklara sahiptir ve model eğitimi sırasında bu ağırlıklar gradyan inişi yöntemiyle optimize edilir. [21]

3.3.3.2 Havuzlama Katmanları

Havuzlama katmanları, öznitelik haritalarının boyutunu azaltarak modelin hesaplama yükünü düşürmek, overfittingi önlemek ve yerel uzamsal değişmezliği sağlamak amacıyla kullanılmaktadır. En yaygın kullanılan havuzlama yöntemi, her bölgedeki maksimum değer seçildiği maksimum havuzlama işlemidir. Alternatif olarak ortalama havuzlama gibi yöntemler de literatürde yer almaktadır.[29]

3.3.3.3 Tam Bağlantılı Katmanlar

Evrişim ve havuzlama işlemlerinin ardından, öğrenilen öznitelik temsilleri vektörel bir forma dönüştürülerek bir veya daha fazla tam bağlantılı katmana aktarılır. Bu katmanlar, klasik yapay sinir ağlarındaki gibi her nöronun bir önceki katmandaki tüm nöronlarla bağlantılı olduğu yapılardır ve genellikle sınıflandırma işleminin gerçekleştirildiği son katmanları oluşturur.

3.3.4 Optimizasyon Algoritmaları

Yapay sinir ağlarının eğitilmesi, çok boyutlu bir parametre uzayında kayıp fonksiyonunu minimize etmeye yönelik optimizasyon sürecine dayanır. Bu amaçla kullanılan optimizasyon algoritmaları, modelin ağırlıklarını iteratif olarak güncelleyerek hedef fonksiyona ulaşmaya çalışır. En yaygın kullanılan yöntemler, türev tabanlı algoritmalarıdır. Bu bölümde, sinir ağı tabanlı modellerin eğitilmesinde sıklıkla kullanılan Gradient Descent, Adam ve RMSprop gibi optimizasyon yöntemleri ele alınacaktır.

3.3.4.1 Gradient Descent

Gradyan inişi parametre optimizasyonu için en temel algoritmalarından biridir. Bu yöntemde, modelin kayıp fonksiyonunun gradyanı hesaplanarak, parametreler bu gradyanın ters yönünde güncellenir.[30] Bu işlem, iteratif olarak tekrarlandığında, modelin parametreleri lokal veya global minimuma doğru ilerler. Gradyan inişi algoritmasının genel güncelleme formülü denklem 5'te verilmiştir.

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} L(\theta_t) \quad (5)$$

Ancak standart Gradient Descent algoritması tüm veri setini aynı anda işlediği için büyük veri kümelerinde hesaplama açısından verimsiz olabilir. Bu nedenle, Stochastic Gradient Descent ve Mini-batch Gradient Descent gibi varyantlar önerilmiştir. [31]

3.3.4.2 Adam (*Adaptive Moment Estimation*)

Adam derin öğrenme modellerinin eğitimi sırasında yaygın olarak kullanılan, etkili ve hesaplama açısından verimli bir optimizasyon algoritmasıdır.[32] Kingma ve Ba tarafından önerilen bu yöntem, klasik Stochastic Gradient Descent'in eksikliklerini gidermeyi amaçlar. Adam, birinci moment ve ikinci moment tahminlerini birleştirerek, her parametre için adaptif öğrenme oranları kullanır. Bu özelliği sayesinde, öğrenme sürecinde hiperparametre ayarlarına karşı daha dayanıklıdır ve farklı veri yapılarıyla uyumlu bir şekilde çalışabilir.

Adam algoritması özellikle yüksek boyutlu parametre uzaylarında ve gürültülü gradyanların söz konusu olduğu durumlarda hızlı yakınsama sağlamasıyla öne çıkar. Bu nedenle, birçok derin öğrenme uygulamasında varsayılan optimizasyon yöntemi olarak tercih edilmektedir.

3.3.5 Eğitim Stratejileri

Yapay sinir ağlarının eğitimi sırasında yalnızca uygun optimizasyon algoritmaları değil, aynı zamanda doğru eğitim stratejileri de modelin başarısını doğrudan etkileyen unsurlardır. Bu stratejiler, modelin eğitim sürecinin etkinliğini artırmak, overfitting gibi olumsuz durumları önlemek ve genel doğruluğu artırmak amacıyla kullanılır. Bu bölümde, eğitim sürecinde yaygın olarak uygulanan tekniklerden bazıları açıklanacaktır.

3.3.5.1 *EarlyStopping, ReduceLRonPlateau*

Erken durdurma , doğrulama kaybı belli bir süre boyunca iyileşmediğinde eğitim sürecini otomatik olarak sonlandırmayı amaçlayan bir yöntemdir. Bu teknik, overfittingi engellemek ve gereksiz eğitim adımlarını ortadan kaldırmak için kullanılır. Eğitim esnasında doğrulama kaybı sürekli olarak izlenir ve belirli bir patience parametresi boyunca iyileşme gözlenmezse eğitim durdurulur[33] Bu strateji, modelin test verisi üzerindeki performansını iyileştirmeye yardımcı olur.

ReduceLRonPlateau, doğrulama kaybı iyileşmediğinde öğrenme oranını belirli bir oranda düşürerek eğitim sürecinin daha hassas bir şekilde devam etmesini sağlar. Bu yöntem, yüksek öğrenme oranıyla hızlı yakınsamayı sağladıktan sonra, lokal minimuma daha düzgün ve kararlı bir biçimde inmek için öğrenme oranını azaltır. Genellikle Adam gibi adaptif algoritmalarla birlikte de kullanılabilir.

Bu strateji; monitor edilen metrik, patience ve factor parametrelerine dayanır ve bu sayede daha istikrarlı bir öğrenme süreci sağlar.

3.3.5.2 *ModelCheckpoint*

ModelCheckpoint, eğitim sırasında belirli aralıklarla veya doğrulama metrikleri iyileştikçe modelin ağırlıklarını kaydeden bir stratejidir. Eğitim süreci sırasında doğrulama kaybı azaldığında veya doğruluk arttığında, mevcut en iyi modelin bir kopyası otomatik olarak diske kaydedilir. Bu sayede modelin overfittinge uğradığı daha sonraki epoch'lardaki ağırlıklar yerine, en iyi performans gösterdiği noktadaki ağırlıklar kullanılabilir. Bu yöntem özellikle, yüksek performanslı bir modelin tekrar elde edilememesi riskini ortadan

kaldırmak için yaygın olarak tercih edilmektedir. ModelCheckpoint, TensorFlow ve PyTorch gibi modern derin öğrenme kütüphanelerinde yerleşik olarak sunulmaktadır[34].

3.3.6 Overfitting

Overfitting, modelin eğitim verisine çok iyi uyum sağlaması ancak eğitimde görülmeyen yeni veriler üzerinde düşük performans göstermesi durumudur. Bu, modelin veri üzerindeki gürültü veya istisnai örnekleri de öğrenmesiyle ilişkilidir. Derin öğrenme modelleri özellikle çok parametrelidir oldukları için bu riski ciddi şekilde taşırlar.

Overfitting'in tespiti için genellikle eğitim ve doğrulama başarımlarının ya da kayıplarının karşılaştırıldığı grafikler incelenir. Eğitim kaybı düşerken doğrulama kaybının artması, overfittingin tipik bir göstergesidir.

3.3.6.1 Dropout

Overfittingi önlemeye yönelik en yaygın kullanılan regularizasyon tekniklerinden biri Dropout yöntemidir. Dropout, eğitim sırasında ağındaki belirli nöronlarının rastgele seçilerek geçici olarak devre dışı bırakılmasını sağlar. Böylece modelin tüm ağırlıklara aynı anda bağımlı hâle gelmesi engellenir ve her eğitim adımında ağındaki farklı bir alt kümesi eğitilmiş olur. Bu yöntem, nöronlar arası bağımlılığı azaltarak daha genel bir temsil öğrenimine katkı sağlar [35]. Bu strateji sayesinde, modelin test verilerinde daha iyi genelleme yapması ve overfitting etkilerinden korunması hedeflenmektedir.

3.4 MODEL MİMARİSİ VE EĞİTİM SÜRECİ

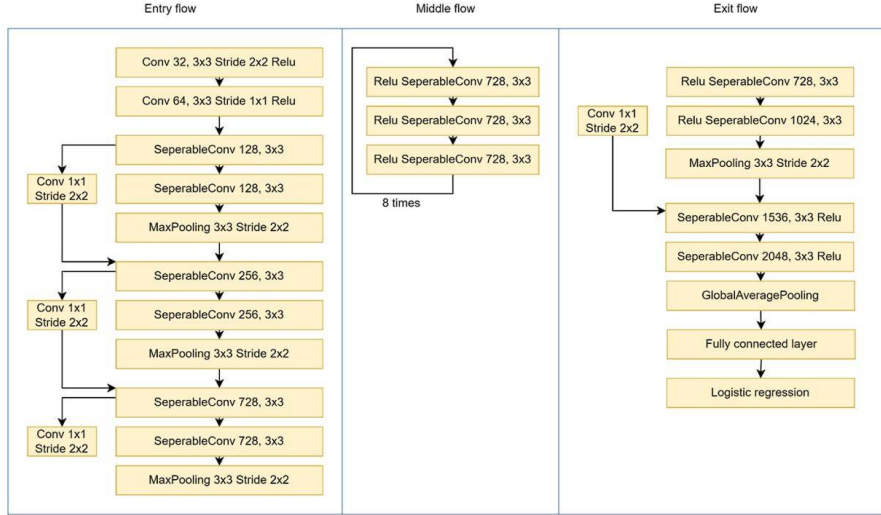
Bu bölümde çalışmamızda kullanılan modelleri ve eğitim sürecinde kullanılan yöntem, algoritma ve parametreler açıklanmıştır.

3.4.1 Kullanılan Modeller

Bu çalışmada, menenjiyoma sınıflandırmasına yönelik olarak farklı derin öğrenme mimarilerinin karşılaştırmalı analizi yapılmıştır. Sınıflandırma görevinde, daha önce ImageNet veri kümesi üzerinde önceden eğitilmiş ve CNN mimarisini barındıran altı farklı model kullanılmıştır: Xception, ResNet50, InceptionV3, DenseNet121, MobileNetV2 ve EfficientNetB0. Bu modeller, transfer öğrenimi yöntemiyle kullanılarak, var olan öğrenilmiş temsillerin yeniden kullanılmasına ve eğitim süresinin önemli ölçüde azaltılmasına olanak tanımıştır.

3.4.1.1 Xception

Xception, 2017 yılında François Chollet tarafından geliştirilen ve Inception mimarisinin daha ileri bir versiyonu olarak sunulan bir CNN mimarisidir. Bu yapı, geleneksel konvolüsyon işlemleri yerine derin ayrık konvolüsyonlar kullanarak hem hesaplama yükünü azaltmakta hem de doğruluk oranını artırmaktadır. Xception üç ana bloktan oluşur: Giriş Bloğu, Orta Akış ve Çıkış Bloğu. Bu bloklar, filtreleme işlemini modülerleştirerek daha verimli özellik çıkarımı yapılmasını sağlar. Şekil 3'te mimari verilmiştir [36].



Şekil 3.3: Xception Mimarisi

Derin ayrık konvolüsyonlar; önce her kanalın ayrı ayrı işlenmesini (depthwise), ardından tüm kanalların 1x1 konvolüsyonla birleştirilmesini (pointwise) içerir. Bu iki adım, klasik konvolüsyon işlemlerine göre daha az parametre ile daha etkili öğrenme sunar.


Xception, özellikle görüntü sınıflandırma ve tıbbi görüntü analizlerinde transfer öğrenme modeli olarak başarıyla kullanılmaktadır[34].

3.4.1.2 ResNet50

ResNet50, 2015 yılında Kaiming He ve arkadaşları tarafından önerilen derin bir CNN mimarisidir [37]. Derin ağlarda yaygın olan gradyan sönmesi problemini önlemek amacıyla geliştirilen bu yapı, artık bağlantılar (residual connections) kullanarak bilgi akışını güçlendirir. Bu bağlantılar, her katmandaki çıktıya girişin doğrudan eklenmesini sağlar.

$F(x)+x$ mekanizması sayesinde, öğrenme sürecini kolaylaştırarak daha derin mimarilerin etkin şekilde eğitilmesini mümkün kılar.

ResNet50, 'bottleneck' adı verilen kompakt bloklar içerir. Bu bloklar; 1x1, 3x3 ve 1x1 evrişim katmanlarından oluşur ve her biri Batch Normalization ve ReLU aktivasyon fonksiyonları ile desteklenir.



Şekil 3.4: ResNet Mimarisi


Şekil 4'te tipik iki artık blok yapısı gösterilmiştir. Görüntü sınıflandırma ve tıbbi görüntü analizi gibi alanlarda yüksek başarı gösteren ResNet50, transfer öğrenme için de güçlü bir temel modeldir.

3.4.1.3 InceptionV3

InceptionV3, Szegedy ve arkadaşları tarafından geliştirilen derin CNN mimarilerinden biridir ve ilk olarak 2016 yılında tanıtılmıştır[38]. Bu model, GoogleNet mimarisinin geliştirilmiş bir versiyonudur ve çok ölçekli öznitelik çıkarımı yapabilen Inception modülleri ile öne çıkar. Modelin en belirgin özelliği, farklı boyutlardaki filtrelerin aynı katmanda paralel olarak uygulanarak hesaplama maliyeti artırılmadan daha derin ve etkili temsiller oluşturabilmesidir. Model, faktörize edilmiş evrişimler, etiket yumuşatma ve gradyan optimizasyonu gibi teknikler ile yüksek doğruluk ve düşük hesaplama maliyeti arasında denge sağlar.

3.4.1.4 DenseNet121

DenseNet121, her katmanın kendisinden önceki tüm katmanlarla doğrudan bağlantı kurduğu yoğun bağlantılı bir CNN mimarisidir [39]. Bu yapı, bilgi kaybını önlerken gradyan akışını güçlendirir ve öğrenilen özelliklerin tekrar kullanılmasını sağlar. Model, dense bloklar ve geçiş katmanlarından oluşur; geçiş katmanlarında 1×1 konvolüsyon ile kanal sayısı azaltılırken 2×2 average pooling ile boyut küçültülür. Bu sayede model hem parametre açısından verimli kalır hem de overfitting riski azalır. Özellikle sınıflandırma problemlerinde yüksek doğruluk ve düşük hata oranı sunan DenseNet'in yapısı Şekil 5'te görsel olarak sunulmuştur.



Şekil 3.5: DenseNet Yapısı

3.4.1.5 MobileNetV2

MobileNetV2, sınırlı işlem gücüne sahip mobil ve gömülü cihazlarda verimli çalışabilmesi amacıyla geliştirilmiş hafif bir CNN mimarisidir. Sandler ve arkadaşları tarafından önerilen bu yapı, özellikle düşük gecikme ve düşük enerji tüketimi gerektiren uygulamalarda etkili sonuçlar vermektedir[40].

MobileNetV2'nin temel yeniliği, inverted residual blokları ve linear bottleneck katmanlarıdır. Bu tasarım hem bilgi kaybını azaltmayı hem de modelin hesaplama karmaşıklığını önemli ölçüde düşürmeyi amaçlar. Bu sayede, yüksek doğruluk seviyeleri korunurken model boyutu ve işlem yükü minimize edilmektedir. Mobil uygulamalar başta olmak üzere çeşitli gerçek zamanlı görüntü işleme görevlerinde yaygın olarak kullanılmaktadır.

3.4.1.6 EfficientNetB0

EfficientNet mimarisi, derin öğrenme modellerinin verimli ölçeklendirilmesini sağlamak amacıyla geliştirilmiştir. Tan ve Le tarafından önerilen bu mimari, ağın derinlik, genişlik ve giriş çözünürlüğü boyutlarını dengeli bir şekilde ölçeklendiren bir yaklaşım sunar. Bu çok boyutlu ölçekleme stratejisi, parametre ve hesaplama maliyetinde belirgin bir artış olmadan model doğruluğunu artırmayı mümkün kılar[41].

EfficientNetB0, bu mimarinin temel yapı taşı olup, otomatik yapılandırma ile elde edilmiştir. Göreli olarak daha küçük model boyutuna rağmen, görüntü sınıflandırma gibi görevlerde yüksek doğruluk sağlamaktadır. Optimize edilmiş katman yapısı ve parametrik verimliliği sayesinde hem eğitim süresi kısaltmakta hem de daha az kaynakla yüksek performans elde edilmektedir.

3.4.2 Değerlendirme Metrikleri ve Yöntemleri

Bu çalışmada geliştirilen derin öğrenme modellerinin başarımı, yalnızca genel doğruluk oranı ile değil; aynı zamanda sınıflandırma dengesini, hata oranlarını ve genelleme kabiliyetini yansıtan çok sayıda metrikle değerlendirilmiştir. Bu kapsamda doğruluk (Accuracy), kesinlik (Precision), duyarlılık (Recall), F1 Skoru, ROC-AUC, Confusion Matrix (Karmaşıklık Matrisi), eğitim ve doğrulama kayıpları gibi metrikler kullanılmıştır [42].

3.4.2.1 Confusion Matrix (Karmaşıklık Matrisi)

Confusion matrix, sınıflandırma modelinin çıktıları ile gerçek değerlerin karşılaştırılarak gösterildiği 2x2 boyutunda bir matristir. Modelin doğru ve yanlış sınıflandırmalarını detaylı biçimde gösterir. Aşağıda tipik bir binary sınıflandırma için kullanılan terimler tablo 1'de verilmiştir.

Gerçek \ Tahmin	Pozitif (1)	Negatif (0)
Pozitif (1)	True Positive (TP)	False Negative (FN)
Negatif (0)	False Positive (FP)	True Negative (TN)

Tablo 3.1: Karmaşıklık Matrisi Gösterimi

Bu matris üzerinden çeşitli başarı metrikleri hesaplanabilmektedir.

3.4.2.2 Doğruluk (Accuracy)

Modelin doğru tahmin oranını ifade eder. Tüm doğru sınıflandırmaların toplam örnek sayısına oranı ile hesaplanır.

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (6)$$

Sınıf dağılımının dengesiz olduğu veri kümelerinde yanıltıcı olabilir.

3.4.2.3 Kesinlik (Precision)

Pozitif tahminlerin ne kadarının gerçekten pozitif olduğunu gösterir. Yanlış pozitif (FP) durumlarının azaltılmasının önemli olduğu senaryolarda kullanılır.

$$Precision = \frac{(TP)}{(TP+FP)} \quad (7)$$

3.4.2.4 Duyarluluk (Recall / Sensitivity)

Gerçek pozitiflerin ne kadarının doğru tahmin edildiğini gösterir. Yanlış negatif (FN) hatalarının azaltılması gereken durumlarda önemlidir.

$$Recall = \frac{(TP)}{(TP+FN)} \quad (8)$$

3.4.2.5 F1 Skoru

Precision ve Recall'un harmonik ortalamasıdır. Her iki değer birlikte değerlendirilmesini sağlar.

$$F_1 = 2 * \frac{(Precision*Recall)}{(Precision+Recall)} \quad (9)$$

3.4.2.6 ROC-AUC

ROC eğrisi, modelin farklı eşik değerlerindeki performansını gösterir. AUC, bu eğrinin altında kalan alanı temsil eder ve modelin sınıflar arasında ayırım yapma kabiliyetini ölçer.

$$TPR = \frac{(TP)}{(TP+FN)}, FPR = \frac{(FP)}{(FP+TN)} \quad (10)$$

ROC eğrisi, modelin farklı eşik değerlerindeki performansını gösterir. AUC, bu eğrinin altında kalan alanı temsil eder.

3.4.2.7 Eğitim Kaybı

Modelin eğitim sürecinde öğrenme başarımını ölçen kayıptır. Bu çalışmada Binary Crossentropy kayıp fonksiyonu kullanılmıştır.

$$Loss = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \quad (11)$$

Modelin eğitim sürecinde öğrenme başarımını ölçen kayıptır.

3.4.2.8 Doğrulama Kaybı

Modelin daha önce görmediği veriler üzerindeki başarımını ölçmek amacıyla hesaplanır. Eğitim ve doğrulama kayıpları arasındaki fark, overfitting olup olmadığını gösterir.

3.4.2.9 Eğitim ve Doğrulama Eğrileri

Modelin eğitim süresince kaydettiği doğruluk ve kayıp değerleri epoch bazlı olarak grafikleştirilmiştir. Bu grafikler modelin öğrenme eğrisini analiz etmek, erken durdurma noktalarını belirlemek ve overfitting riskini kontrol etmek için kullanılmıştır. Eğitim kaybı düşerken, doğrulama kaybı artıyorsa overfittinge bir işaret olduğu söylenebilir.

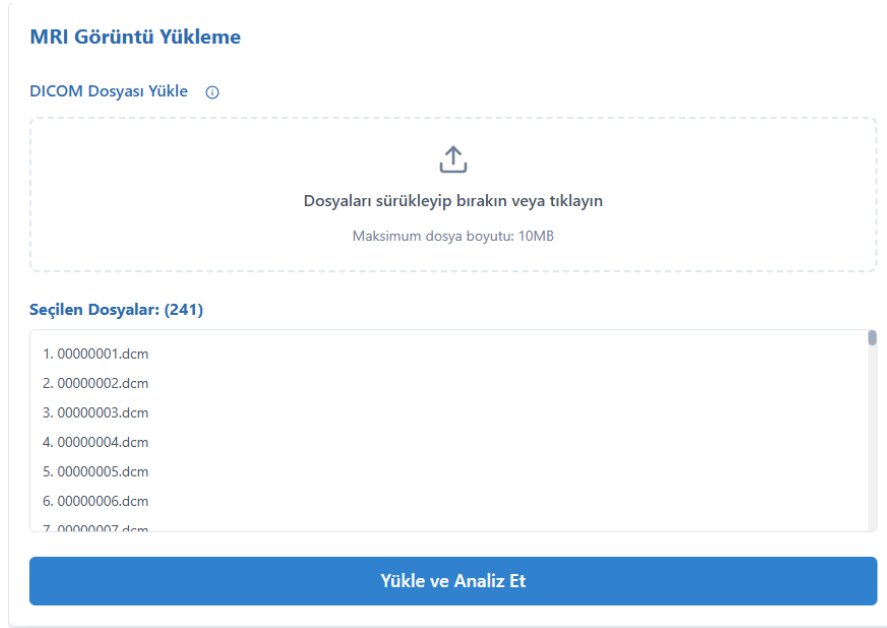
3.5 SİSTEM MİMARİSİ

Geliştirilen sistem; kullanıcı arayüzü, sunucu uygulaması ve yapay zekâ modeli olmak üzere üç ana katmandan oluşan bütünleşik ve modüler bir mimariye sahiptir. Bu yapı, hem kullanıcı deneyimini hem de teknik sürdürülebilirliği ön planda tutacak şekilde tasarlanmıştır. Aşağıda her katman ayrı ayrı açıklanmış, veri akışı ve bileşen ilişkileri diyagramlarla desteklenmiştir.

3.5.1 Frontend

Frontend yapısı, kullanıcının sistemle etkileşime geçtiği, modern web teknolojileriyle geliştirilmiş dinamik bir arayüzdür. Kullanıcılar, DICOM tıbbi görüntüleri sisteme kolayca yükleyebilir, analiz sürecini başlatabilir ve sonuçları hem görsel hem de metinsel biçimde anlık olarak görüntüleyebilir. Ayrıca analiz sonuçlarını PDF formatında dışa aktarma imkânı da sunulmuştur.

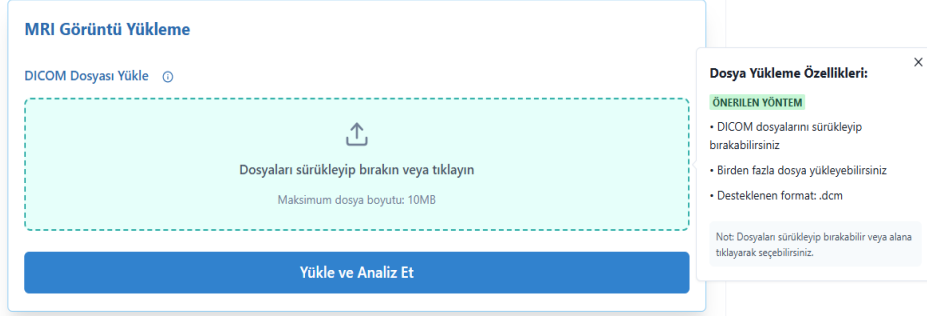
3.5.1.1 Yüklenen DICOM Dosyalarının Liste Görünümü



Şekil 3.6: Yükleme Ekranı

Şekil 6'da Kullanıcının sistem arayüzü üzerinden yüklediği çok sayıda DICOM dosyasının, alfabetik/sayısal sırayla listelendiği ve kaydırılabilir (scrollable) bir liste içerisinde gösterildiği kullanıcı arayüzü bileşeni. Bu özellik sayesinde kullanıcı, yüklediği dosyaları işlem öncesinde gözden geçirme ve doğrulama imkânına sahip olmaktadır. Aynı zamanda kullanıcı deneyimini iyileştiren bu yapı, çoklu dosya yönetimini kolaylaştırmakta ve sistemin etkileşim kabiliyetini artırmaktadır.

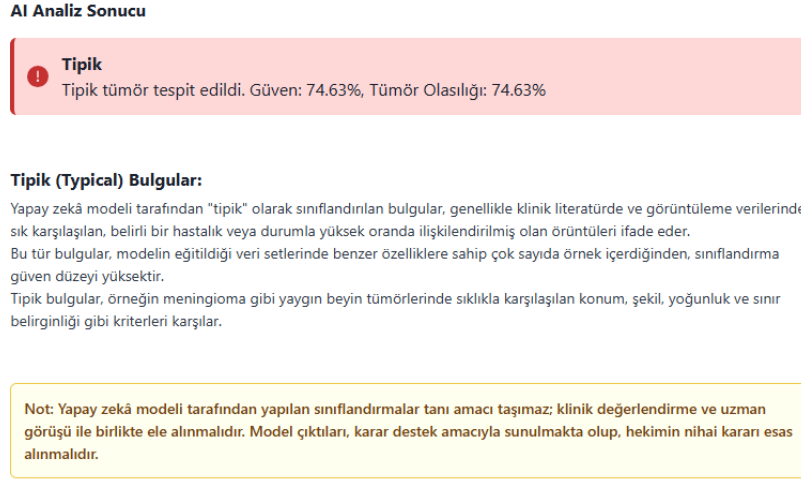
3.5.1.2 Dosya Yükleme Arayüzü (Sürükle, Bırak ve Seçim Destekli)



Şekil 3.7: Dosya Yükleme Arayüzü

Şekil 7’de gösterildiği gibi sistem arayüzünde yer alan bu bileşen, kullanıcının DICOM formatındaki tıbbi görüntüleri sisteme kolayca yüklemesini sağlayan interaktif bir alandır. Dosya yükleme işlemi, hem geleneksel seçim yöntemiyle hem de sürükle-bırak özelliğiyle desteklenmektedir. Görselde, kullanıcıya maksimum dosya boyutu, desteklenen format ve birden fazla dosya yükleyebilme gibi bilgiler kutucuk içinde sunulmaktadır. Bu yapı sayesinde kullanıcı, teknik bilgi gerektirmeksizin dosya yükleme işlemi hızlı ve güvenli biçimde gerçekleştirebilir. Bu da kullanıcı deneyimini doğrudan olumlu yönde etkilemektedir.

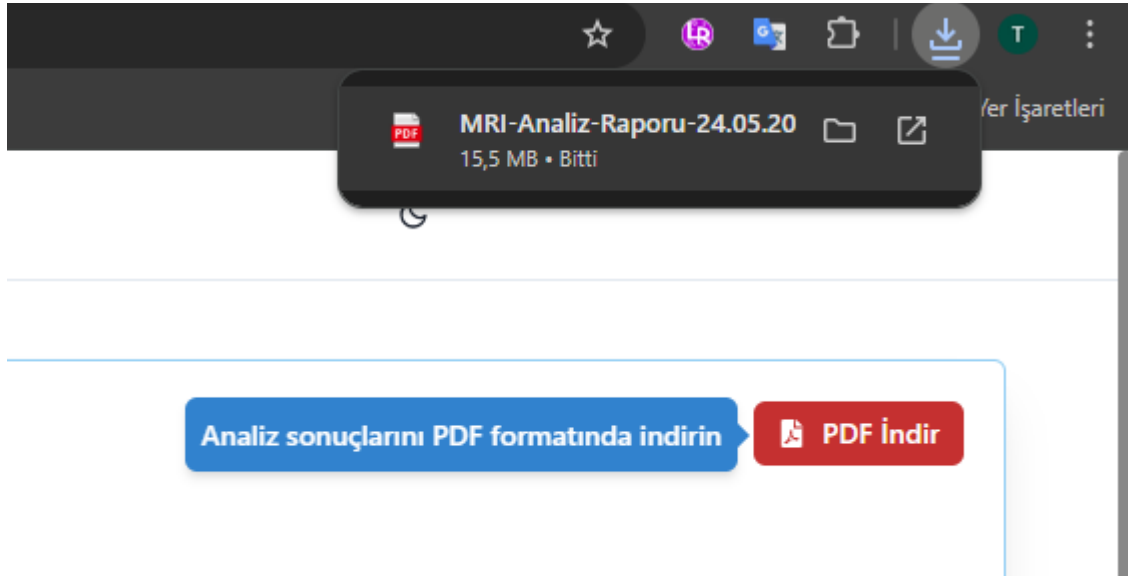
3.5.1.3 Model Tahmin Sonucu ve Güven Skoru Arayüzü



Şekil 3.8: Model Tahmin Sonucu Ekranı

Şekil 8’de görüldüğü üzere model tarafından yapılan sınıflandırma sonucunun kullanıcıya nasıl sunulduğu gösterilmektedir. Sistem, tahmin edilen tümör sınıfını (örneğin: ‘Tipik’) vurgulu bir uyarı kutusu içerisinde belirtmekte, aynı zamanda bu sınıfa ait güven skoru (%74.63) ve tümör olasılığı (%74.63) gibi nicel verileri detaylı şekilde kullanıcıya sunmaktadır. Alt bölümde yer alan açıklayıcı içerik sayesinde model çıktısının tıbbi bağlamı kullanıcıya aktarılmakta; sonuçların yalnızca karar destek amaçlı olduğu, nihai teşhisin hekim tarafından yapılması gerektiği vurgulanmaktadır. Bu yapı, kullanıcı bilgilendirmesini güçlendirirken, sistemin etik ve doğru kullanımına da katkı sağlar.

3.5.1.4 Yapay Zekâ Analiz Sonuçlarının PDF Formatında Dışa Aktarımı



Şekil 3.9: Dışa Aktarım Ekranı

Şekil 9’da görüldüğü gibi sistem, yapay zekâ tarafından üretilen analiz sonuçlarını yalnızca ekran üzerinde sunmakla kalmayıp, kullanıcıya PDF formatında dışa aktarma imkânı da tanımaktadır. Görselde, kullanıcıya ‘PDF İndir’ butonu ile sunulan çıktı işlemi sonucunda, sistem tarafından oluşturulan analiz raporu başarıyla tarayıcı üzerinden indirilmiş olarak gösterilmektedir. Bu özellik, kullanıcıların analiz sonuçlarını arşivleyebilmesini, sağlık uzmanlarıyla paylaşabilmesini ve klinik dökümantasyon süreçlerine entegre edebilmesini sağlamaktadır. Ayrıca, çıktıların otomatik tarihli dosya adıyla oluşturulması, düzenli dosya yönetimini desteklemektedir.

3.5.1.5 Geçersiz Dosya Yükleme Durumunda Anlık Uyarı Mesajı



Şekil 3.9: Uyarı Mesajına Örnek

Şekil 10’da görüldüğü üzere sistem, yalnızca DICOM (.dcm) formatında dosyaların yüklenmesine izin vermektedir. Görselde, kullanıcının geçersiz bir dosya yüklemesi durumunda karşılaştığı anlık uyarı mesajı yer almaktadır. Uyarı kutusu, kullanıcıyı hatalı giriş konusunda bilgilendirmekte ve doğru dosya türünün ne olması gerektiğini açıkça belirtmektedir. Bu özellik, kullanıcı hatalarını önlemeye yönelik tasarlanmış olup; sistemin güvenilirliğini artırmakta ve kullanıcı deneyimini iyileştirmektedir. Uyarılar, React Toastify bileşeni kullanılarak ekranın sağ üst köşesinde geçici olarak gösterilmektedir.

3.5.1.6 Yapay Zekâ Tabanlı MRI Analiz Raporu Arayüzü

DICOM Analiz Raporu

PDF İndir

BAŞARILI

MRI Analiz Raporu

👤 DICOM Bilgileri

Hasta Adı	Ali Veli Mehmet
Doğum Tarihi	01.01.1900
Cinsiyet	Erkek
Çekim Tarihi	01.01.2000
Çekim Saati	09:32:54
İnceleme Açıklaması	MRG, BEYİN, KONTRASTLI
Modalite	MR
Slice Kalınlığı	5.5

📷 Görüntü Bilgileri

<p>Görüntü Boyutu 512 x 512 <small>Piksel</small></p>	<p>Kesit Kalınlığı 5.5 <small>mm</small></p>
<p>Ortalama Piksel Değeri 298.74</p>	<p>Piksel Değer Aralığı 0 - 2391</p>

AI Analiz Sonucu

⚠️ Tipik
Tipik tümör tespit edildi. Güven: 74.63%, Tümör Olasılığı: 74.63%

Tipik (Typical) Bulgular:

Yapay zekâ modeli tarafından "tipik" olarak sınıflandırılan bulgular, genellikle klinik literatürde ve görüntüleme verilerinde sık karşılaşılan, belirli bir hastalık veya durumla yüksek oranda ilişkilendirilmiş olan görüntüleri ifade eder. Bu tür bulgular, modelin eğitildiği veri setlerinde benzer özelliklere sahip çok sayıda örnek içerdiğinden, sınıflandırma güven düzeyi yüksektir. Tipik bulgular, örneğin meningioma gibi yaygın beyin tümörlerinde sıklıkla karşılaşılan konum, şekil, yoğunluk ve sınır belirginliği gibi kriterleri karşılar.

Not: Yapay zekâ modeli tarafından yapılan sınıflandırmalar tanı amacı taşımaz; klinik değerlendirme ve uzman görüşü ile birlikte ele alınmalıdır. Model çıktıları, karar destek amacıyla sunulmakta olup, hekimin nihai kararı esas alınmalıdır.

Şekil 3.10: MRI Analiz Raporu Arayüzü

Şekil 11'deki görselde, sistemin kullanıcıya sunduğu analiz raporu ekranı yer almaktadır. Sayfa; hasta bilgileri, görüntüleme tarihleri, modality (MR), görüntü çözünürlüğü, piksel değer aralığı ve kesit kalınlığı gibi DICOM metadata alanlarının düzenli biçimde sunulduğu bir yapıya sahiptir. Ayrıca, yapay zekâ modeli tarafından üretilen sınıflandırma sonucu ve bu

sonuca ilişkin güven skoru sistematik olarak kullanıcıya aktarılmıştır. Sayfa sonunda yer alan bilgilendirme kutusu ise kullanıcıya model çıktılarının yalnızca karar destek amacı taşıdığını, tıbbi kararın hekim tarafından verilmesi gerektiğini hatırlatmaktadır. Bu arayüz, klinik karar süreçlerine katkı sağlayabilecek net, sade ve profesyonel bir raporlama ekranı örneğidir.

3.5.2 Backend (Sunucu Uygulaması)

Backend yapısı, yüksek performanslı, güvenli ve ölçeklenebilir bir API altyapısı sunmak amacıyla Python dilinde ve FastAPI çatısı kullanılarak geliştirilmiştir. Sistem; gelen DICOM, JPEG veya PNG formatındaki görüntüleri işler, yapay zekâ modeline yönlendirir ve çıktıyı kullanıcıya anlamlı şekilde iletir. Yapı, modüler bir mimari ile organize edilmiştir ve çeşitli servis bileşenleri, iş mantığı sınıfları ve doğrulama katmanlarından oluşmaktadır.

3.5.2.1 DICOM Görüntü İşleme ve Doğrulama Süreci

DICOM görüntü işleme süreci, sistemin kullanıcıdan gelen tıbbi görüntüleri analiz edilebilir forma getirmesiyle başlar. İlk olarak, kullanıcı tarafından yüklenen .dcm uzantılı DICOM dosyası alınır ve bu dosya pydicom kütüphanesi aracılığıyla okunur. Ardından, görüntüye gömülü bulunan metadata bilgileri (hasta kimliği, modalite türü, slice kalınlığı gibi) ayrıştırılır. Görüntü verisinin piksel bilgileri, işlenebilir hâle gelmesi için NumPy dizilerine dönüştürülür. Devamında, yüklenen dosyanın tipi, çözünürlük değeri ve modalite bilgisi gibi parametreler kontrol edilerek belirlenen standartlara uygunluğu doğrulanır. Uygun olmayan dosyalar sistemden ayrıştırılır; bu tür durumlarda kullanıcıya bilgilendirici bir hata mesajı gösterilir ve eş zamanlı olarak log kaydı oluşturulur. Bu işlem hattı sayesinde yalnızca analiz edilebilir kalite ve formattaki görüntüler modele yönlendirilir.

3.5.2.2 Yapay Zekâ Modeli Entegrasyonu ve Tahmin Süreci

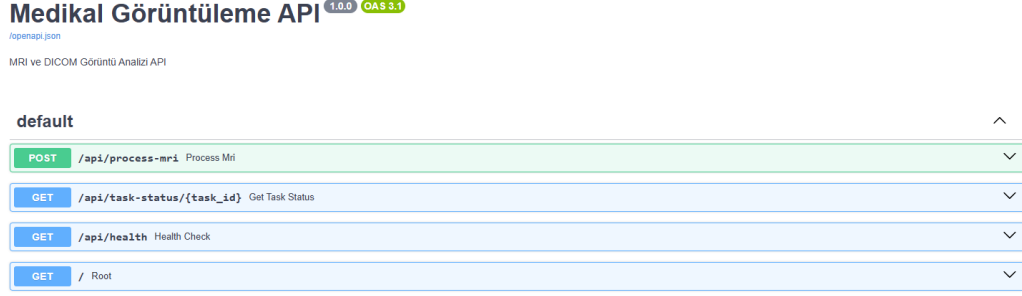
Yapay zekâ modeliyle gerçekleştirilen görüntü sınıflandırma süreci, medikal verilerin tanı amaçlı anlamlandırılması için yapılandırılmış bir işlem hattı izler. Bu süreçte, öncelikle model girişine gönderilecek olan görüntüler ön işleme (preprocessing) aşamasında normalize edilir ve standart giriş boyutu olan 224x224 piksel boyutuna yeniden ölçeklendirilir. Ardından görüntüler, tek kanallı (grayscale) forma dönüştürülerek modelin beklentisine uygun hâle getirilir. Sınıflandırma işlemi, eğitilmiş yapay zekâ modeli üzerinden model.predict() fonksiyonu aracılığıyla gerçekleştirilir. Model çıktısı olarak, tümörün sınıfı (tipik veya non-tipik), buna ait bir güven skoru ve sınıflandırma olasılık değeri elde edilir. Elde edilen bu sonuçlar JSON formatında yapılandırılarak kullanıcı arayüzüne iletmek üzere frontend katmanına aktarılır. Böylece, tıbbi görüntülerden elde edilen veriler sınıflandırılarak sistemin karar destek mekanizması güçlendirilmiş olur.

3.5.2.3 Hata Yönetimi ve Loglama Sistemi

Sistemin güvenilirliğini artırmak ve sürdürülebilir bakım süreçlerini kolaylaştırmak amacıyla kapsamlı bir hata yönetim mekanizması geliştirilmiştir. Bu mekanizma, çeşitli kontrol adımlarını içermektedir. Öncelikle, yüklenen dosyaların format doğrulaması, eksik veri kontrolleri ve yapay zekâ modeline ait olası tahmin hatalarının yakalanması gibi işlemler gerçekleştirilir. Hatalı durumlar, ilgili HTTP hata kodları (örneğin 400 – hatalı istek, 422 – işlenemeyen varlık, 500 – sunucu hatası) kullanılarak kullanıcıya anlamlı yanıtlar şeklinde iletir. Bu hata yanıtları yapılandırılmış JSON formatında üretilmekte ve sistem log dosyalarına otomatik olarak kaydedilmektedir. Ayrıca, bu log kayıtları isteğe bağlı olarak harici izleme (monitoring) sistemlerine de aktarılabilir. Geliştirilen bu yapı sayesinde sistem

içerisindeki tüm başarısızlıklar anlık olarak izlenebilir hâle gelmiş, geliştiricilerin hatalara hızlı şekilde müdahale edebilmesi mümkün olmuştur.

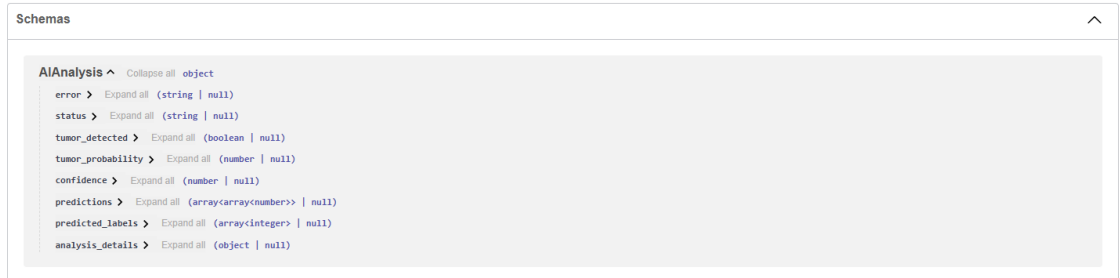
3.5.2.4 Medikal Görüntüleme API Uç Noktaları



Şekil 3.11: Medikal Görüntüleme API

Şekil 15’te sistemin FastAPI ile geliştirilmiş RESTful uç noktaları yer almaktadır. /api/process-mri uç noktası POST isteğiyle MRI analiz sürecini başlatır; /api/task-status/{task_id} analiz durumunu sorgulamak için kullanılır; /api/health uç noktası sistemin genel durumunu kontrol eder. Tüm bu uç noktalar Swagger arayüzü üzerinden interaktif olarak test edilebilmektedir.

3.5.2.5 AIAnalysis Yanıt Modeli Şeması



Şekil 3.12: AIAnalysis Yanıt Modeli Şeması

Şekil 16’da yapay zekâ sınıflandırma sürecinden dönen AIAnalysis veri modeli; hata mesajları, tümör olup olmadığına dair karar (tumor_detected), olasılık (tumor_probability), güven skoru (confidence) ve analiz detaylarını içermektedir. Bu model sayesinde kullanıcıya tahmin sonuçları anlaşılır ve güvenilir şekilde sunulmaktadır.

3.5.2.6 SampleMetrics Yanıt Modeli Şeması

```

Fileinfo ^ Collapse all object
  patient_name > Expand all (string | null)
  patient_id > Expand all (string | null)
  birth_date > Expand all (string | null)
  sex > Expand all (string | null)
  study_date > Expand all (string | null)
  study_time > Expand all (string | null)
  accession_number > Expand all (string | null)
  study_description > Expand all (string | null)
  modality > Expand all (string | null)
  slice_thickness > Expand all (string | null)
  manufacturer_model > Expand all (string | null)
  manufacturer > Expand all (string | null)
  body_part > Expand all (string | null)
  pixel_spacing > Expand all (array<number> | null)
  rows > Expand all (integer | null)
  columns > Expand all (integer | null)
  image_size > Expand all (object | null)

```

Şekil 3.13: SampleMetrics API Modeli

Şekil 17 'de görüntü üzerinde yapılan temel istatistiksel hesaplamalar SampleMetrics şeması ile sunulmaktadır. Ortalama, maksimum ve minimum piksel değerleri; tahmini tümör derecesi (tumorGrade), olasılık ve güven skoru gibi metrikler model sonuçlarına ek olarak kullanıcıya sunulur.

3.5.2.7 ProcessingResult Yanıt Modeli Şeması

```

ProcessingResult ^ Collapse all object
  taskId* string
  status* string
  processed > Expand all boolean
  message > Expand all (string | null)
  timestamp > Expand all (string | null)
  file_info > Expand all (object | null)
  sample_metrics > Expand all (object | null)
  is_tumor > Expand all (boolean | null)
  tumorGrade > Expand all (integer | null)
  probability > Expand all (number | null)
  confidence > Expand all (number | null)
  analysis_details > Expand all (object | null)

```

Şekil 3.14: ProcessingResult API Modeli

Şekil 18'de model, analiz işlemine ait genel durum bilgilerini içermektedir. Her işleme özel bir taskId tanımlanır; işlenme durumu (processed), hata mesajı, analiz zamanı (timestamp) ve sample_metrics, file_info gibi detaylı veri nesnelere bu model altında toplanır.

3.5.2.7 FileInfo Görüntü Metadeta Şeması

```

SampleMetrics ^ Collapse all object
  mean_pixel_value > Expand all (number | null)
  max_pixel_value > Expand all (number | null)
  min_pixel_value > Expand all (number | null)
  ai_analysis > Expand all (object | null)
  hasTumor > Expand all (boolean | null)
  tumorGrade > Expand all (integer | null)
  probability > Expand all (number | null)
  confidence > Expand all (number | null)
  analysis_details > Expand all (object | null)

```

Şekil 3.15: FileInfo API Modeli

Şekil 3.19’de sisteme yüklenen DICOM görüntülerine ait metadata bilgileri FileInfo nesnesi içerisinde saklanır. Hasta adı, yaş, modality, görüntü boyutu, çözünürlük, slice kalınlığı, üretici cihaz gibi tıbbi veriler bu şema üzerinden kullanıcılara aktarılır. Bu yapı, model tahminlerinin yanı sıra klinik doğrulama sürecine de katkı sunar.

3.5.3 AI Katmanı (Model Entegrasyonu)

Yapay zekâ katmanı, ‘.keras’ uzantılı olarak eğitilmiş bir Xception mimarisi üzerine inşa edilen modelin sistemle entegre edilmesiyle oluşturulmuştur. Bu model, MRI görüntülerini analiz ederek 0 ile 1 arasında bir olasılık değeri üretmektedir. Söz konusu olasılık değeri, tümörün tipik veya non-tipik olma durumunu belirlemek amacıyla kullanılmaktadır. Bu kapsamda, eşik değeri olarak 0.5 alınmakta ve bu değer üzerindeki olasılıklar ‘Non-Tipik’, altındaki değerler ise ‘Tipik’ olarak sınıflandırılmaktadır.

Modelin analiz sonucunda oluşturduğu çıktı üç temel bilgiyi içermektedir. Bunlardan ilki, sınıflandırma sonucunu ‘Tipik’ veya ‘Non-Tipik’ olarak belirten predicted_class değeridir. İkinci olarak, tahminin güven düzeyini temsil eden confidence değeri hesaplanmaktadır. Son olarak, tumor_probability alanında modelin tümör tespiti konusundaki olasılık tahmini yer almaktadır.

Bu veriler, sistemin ön yüz bileşenine JSON formatında iletilmekte ve kullanıcıya anlaşılır bir şekilde sunulmaktadır. Bu yapı sayesinde, analiz süreci hem hızlı hem de güvenilir bir şekilde gerçekleştirilerek kullanıcıya anlık geri bildirim sağlanmaktadır.

3.6 EK ÖZELLİKLER

3.6.1 Tema Desteği

Sistem, açık ve koyu mod (light/dark theme) olmak üzere iki farklı tema desteğine sahiptir. Kullanıcı tercihlerine göre arayüz dinamik olarak uyum sağlar.

3.6.2 Yeni Modül Geliştirme

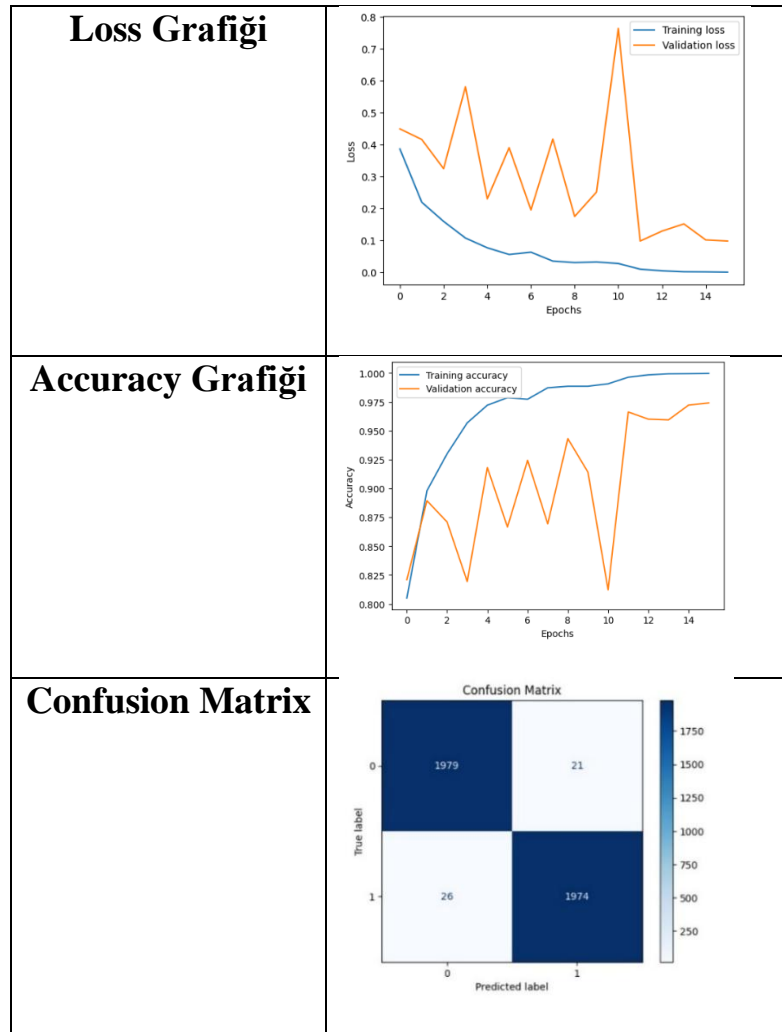
Omurga kırığı tespiti gibi farklı görüntüleme problemlerine yönelik yeni modüller geliştirilmektedir. Sistem, bu modüllerin entegrasyonuna uygun genişletilebilir yapıda tasarlanmıştır.

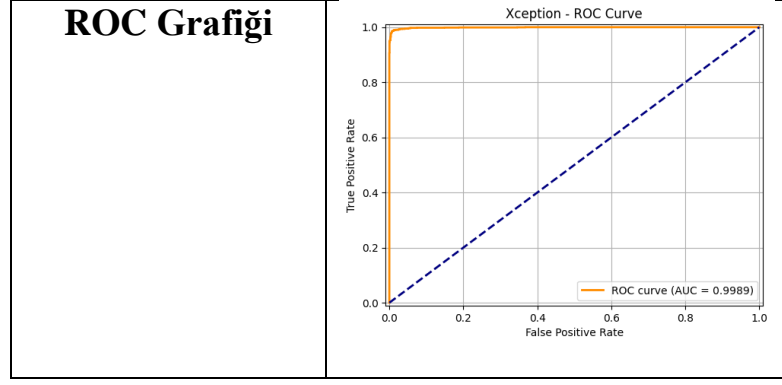
4. BULGULAR

4.1 MODEL ÇIKTILARININ İNCELENMESİ

Modellerin başarı düzeyleri, ROC eğrileri, karmaşıklık matrisleri ile eğitim ve doğrulama sürecine ait kayıp grafiklerinin bütüncül analiziyle değerlendirilmiştir. Bu grafiksel çıktılar, modelin öğrenme süreci, sınıflandırma doğruluğu ve genelleme yeteneği hakkında ayrıntılı içgörüler sunmaktadır.

4.1.1 XCEPTION

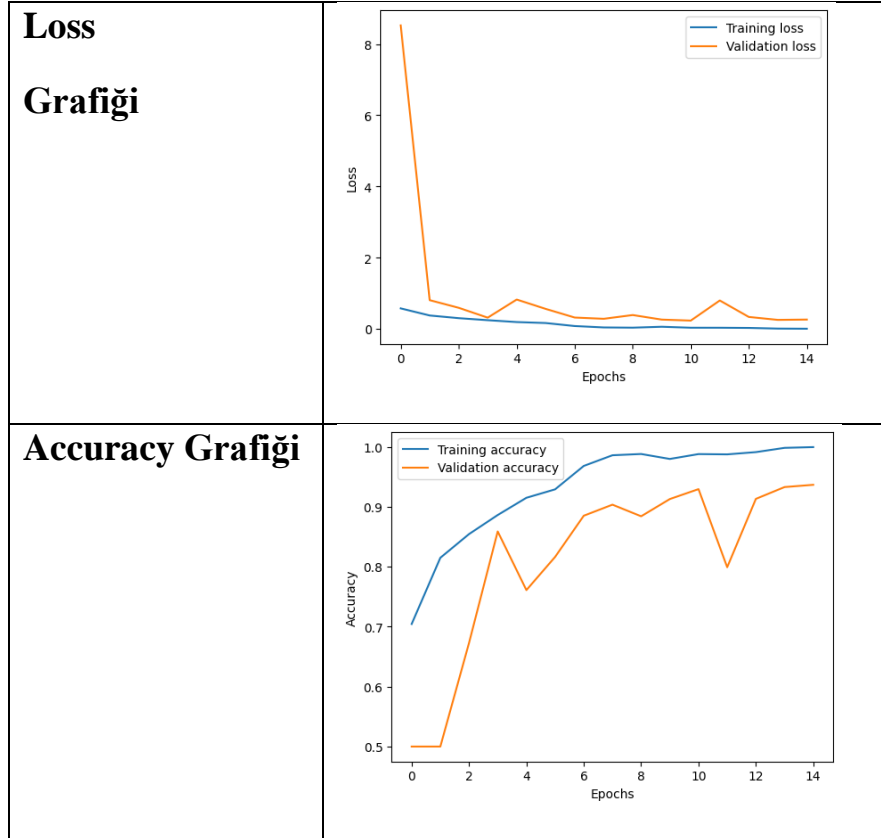


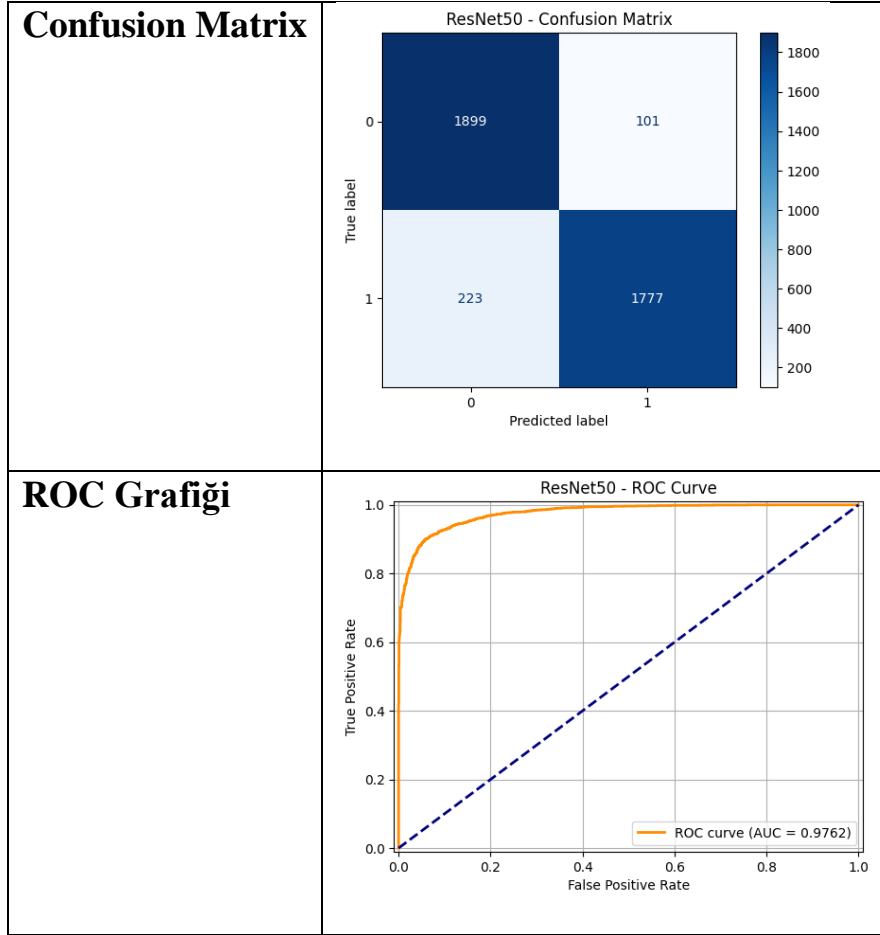


Tablo 4.2: Xception Test Sonuçları

Tablo 2’de sunulan grafikler, Xception mimarisi ile eğitilen modelin öğrenme sürecindeki başarımını kapsamlı biçimde ortaya koymaktadır. Eğitim ve doğrulama kaybı eğrileri incelendiğinde, eğitim kaybının her bir epoch boyunca istikrarlı şekilde azaldığı; buna karşın doğrulama kaybının bazı epoch’larda dalgalanmalar gösterdiği görülmektedir. Özellikle 10. epoch’ta gözlenen ani yükseliş, modelin bu noktada overfitting eğilimine girdiğini ve erken durdurma stratejisinin gerekliliğini ortaya koymaktadır. Eğitim doğruluğu eğrisi neredeyse %100’e ulaşmış, doğrulama doğruluğu ise %98 civarında sabitlenerek güçlü bir genelleme başarısı sergilemiştir. Confusion Matrix değerlendirmesinde, her iki sınıf için doğru sınıflandırma oranlarının yüksek olduğu; ancak sınıf sınırında kalan örneklerde bazı hatalı tahminlerin gerçekleştiği görülmektedir. Buna rağmen ROC eğrisinden elde edilen 0.9989 AUC skoru, modelin pozitif ve negatif sınıflar arasında yüksek doğrulukla ayırım yapabildiğini ve genel sınıflandırma performansının oldukça güçlü olduğunu ortaya koymaktadır.

4.1.2 RESNET 50





Tablo 4.3: ResNET50 Test Sonuçları

Tablo 2’de gösterilen eğitim ve doğrulama kaybı eğrileri, modelin öğrenme sürecinde hızlı bir şekilde stabil hale geldiğini göstermektedir. Başlangıçta validation loss değerinin oldukça yüksek olması, veri dengesizliği ya da modelin henüz genel örüntüleri öğrenememesinden kaynaklanmaktadır. Ancak birkaç epoch içerisinde bu değerler düşmüş, training ve validation loss birbirine yakınsamıştır. Bu durum, modelin overfitting eğilimi göstermediğini ve genelleme kapasitesinin yüksek olduğunu göstermektedir.

Doğruluk eğrileri incelendiğinde, eğitim doğruluğu neredeyse 1.00 seviyelerine kadar çıkarken, doğrulama doğruluğu %93’ler civarında kalmıştır. Bu fark, küçük bir overfitting işareti olarak yorumlansa da, validation accuracy eğrisinin genel olarak stabil seyretmesi, modelin yeterli genelleme yaptığını göstermektedir.

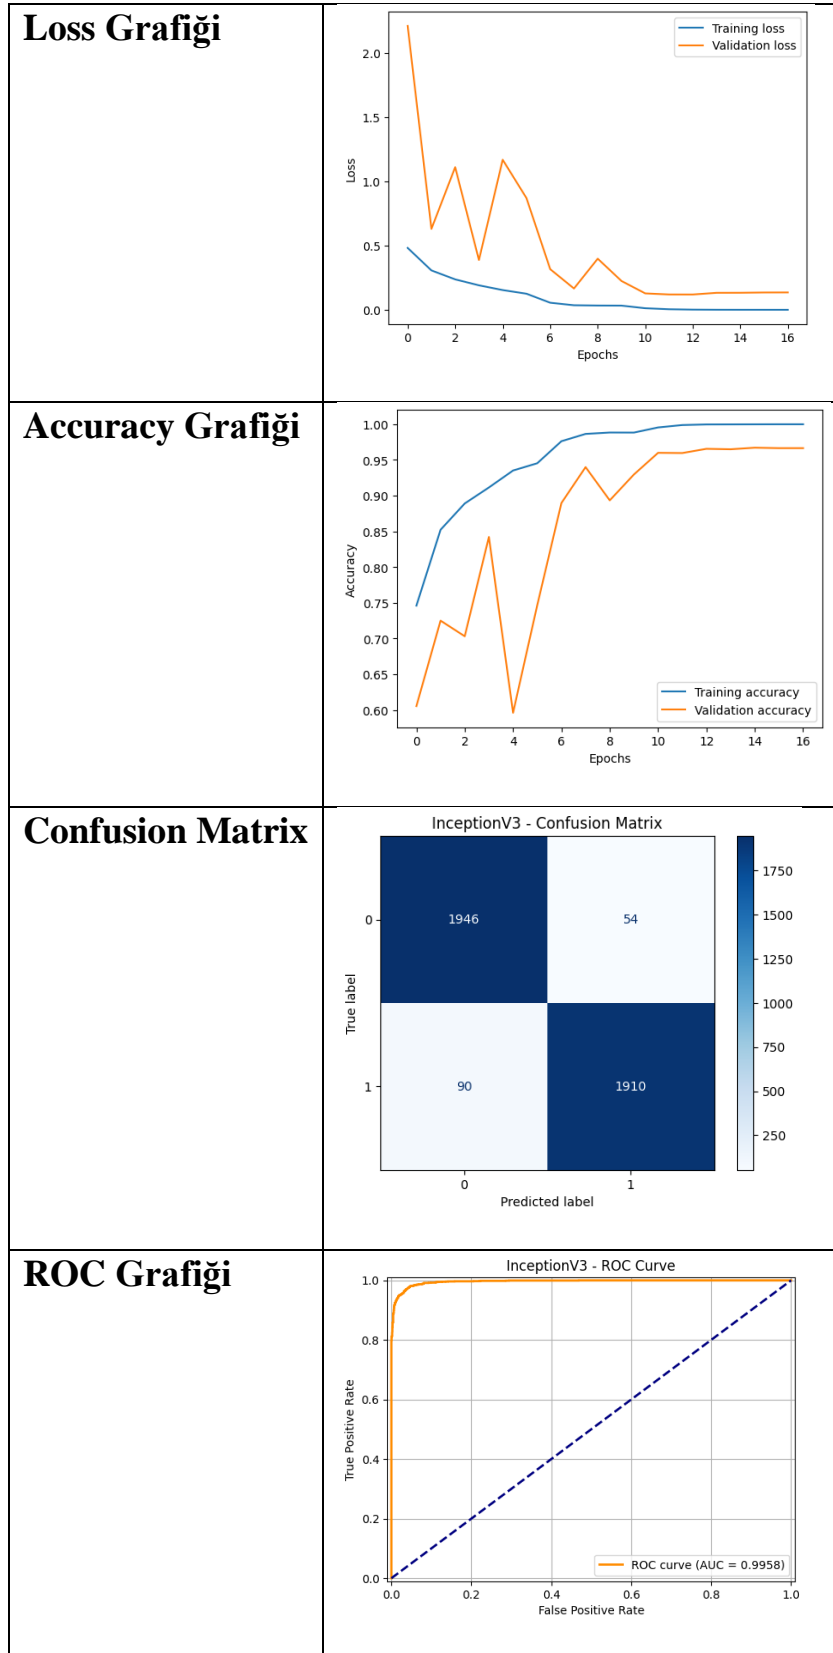
Confusion matrix’e göre model; 1899 gerçek negatif ve 1777 gerçek pozitif örneği doğru sınıflandırırken, 101 yanlış pozitif ve 223 yanlış negatif sınıflandırma yapmıştır. Bu tablo, modelin özellikle pozitif sınıfta yüksek başarı sağladığını, ancak negatif sınıflamada bazı sınırlı hatalar yaptığını ortaya koymaktadır.

ROC eğrisi ve AUC skoru (0.9762), modelin sınıflar arasında ayırım yapma kabiliyetinin oldukça yüksek olduğunu göstermektedir. Eğrinin sol üst köşeye yakın seyretmesi, modelin yanlış pozitif oranını düşük tutarak yüksek doğru pozitif oranı sağladığını kanıtlamaktadır.

Sonuç olarak, ResNet50 modeli genel olarak hem eğitim hem de test verileri üzerinde başarılı bir performans sergilemiş, overfitting riski minimal düzeyde kalmış ve ROC-AUC değeriyle

yüksek ayrıştırma başarısı elde etmiştir. Bu durum, ResNet50'nin meningioma sınıflandırma görevinde güvenilir bir model adayı olduğunu göstermektedir.

4.1.3 INCEPTION V3



Tablo 4.4: InceptionV3 Test Sonuçları

Tablo 3'te gösterilen sonuçlara göre, InceptionV3 modeli hem doğruluk hem de kayıp açısından oldukça dengeli bir performans ortaya koymuştur. Eğitim kaybı, epoch'lar boyunca istikrarlı şekilde azalarak modelin öğrenme sürecini başarıyla tamamladığını göstermektedir. Benzer şekilde doğrulama kaybı da ilk epoch'lardan itibaren hızlı bir düşüş sergileyerek modelin genelleme kabiliyetinin geliştiğini göstermektedir.

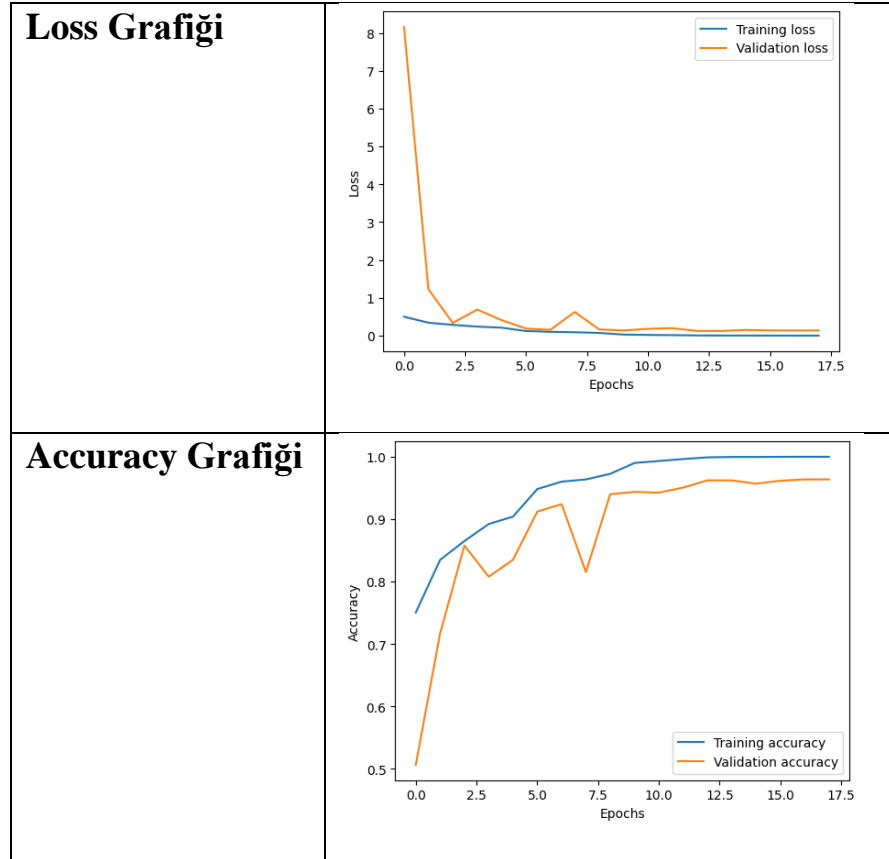
Doğruluk Grafiği incelendiğinde, eğitim doğruluğunun %99'un üzerine çıktığı ve doğrulama doğruluğunun ise yaklaşık %96 seviyesine ulaştığı gözlemlenmektedir. Bu durum, modelin eğitim verisine iyi uyum sağladığını ve overfitting'e uğramadan yeni veriler üzerinde de güçlü tahminler üretebildiğini ortaya koymaktadır.

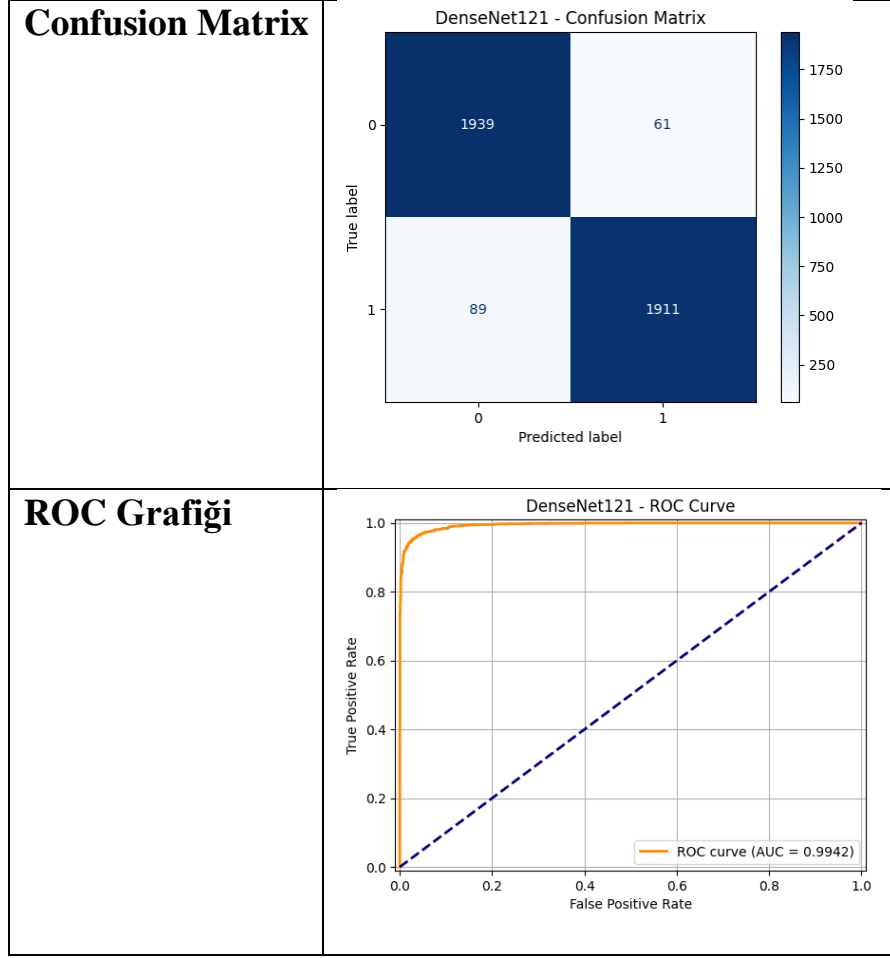
Confusion Matrix sonuçlarına göre, model 2000'er görüntüden oluşan her iki sınıfta da yüksek doğruluk oranı sergilemiştir. Tipik tümör sınıfında (sınıf 1) 1910 doğru sınıflandırma (TP) yapılırken yalnızca 90 yanlış sınıflandırma (FN) görülmüştür. Benzer şekilde Non-Tipik tümör sınıfında da 1946 doğru tahmin ve 54 hata gözlenmiştir. Bu değerler, modelin hem hassasiyet (recall) hem de kesinlik (precision) açısından güçlü bir denge kurduğunu göstermektedir.

Son olarak, ROC eğrisi altında kalan alanın ($AUC = 0.9958$) neredeyse bire çok yakın olması, InceptionV3 modelinin sınıflar arasında oldukça iyi ayırım yapabildiğini doğrulamaktadır. ROC eğrisinin eğimi, pozitif ve negatif sınıflar için yüksek ayırt ediciliği temsil eder.

Bu kapsamlı sonuçlar, InceptionV3 mimarisinin meningioma sınıflandırma görevinde son derece etkili bir model olduğunu ve hem istatistiksel metrikler hem de grafiksel analiz açısından yüksek başarı sağladığını ortaya koymaktadır.

4.1.4 DENSENET 121





Tablo 4.5: DenseNet121 Test Sonuçları

Tablo 5’de gösterilen DenseNet121 modeline ait grafikler incelendiğinde, modelin hem eğitim hem de doğrulama süreçlerinde istikrarlı bir öğrenme eğrisi sergilediği görülmektedir. İlk epoch’larda validation loss değerlerinde dalgalanmalar olsa da, ilerleyen epoch’larda bu değer belirgin şekilde düşmekte ve 10. epoch itibarıyla stabilize olmaktadır. Eğitim kaybı da sürekli azalan bir seyir izlemekte ve 0’a yakınsamakta, bu da modelin eğitim verisine oldukça başarılı şekilde adapte olduğunu göstermektedir.

Doğruluk Grafiği incelendiğinde, eğitim doğruluğunun %99 seviyesine ulaştığı, doğrulama doğruluğunun ise %97 civarında sabitlendiği görülmektedir. Bu durum, modelin yalnızca eğitim verisini değil, daha önce görmediği verileri de yüksek başarıyla sınıflandırabildiğini göstermektedir. Overfitting riski oldukça düşüktür.

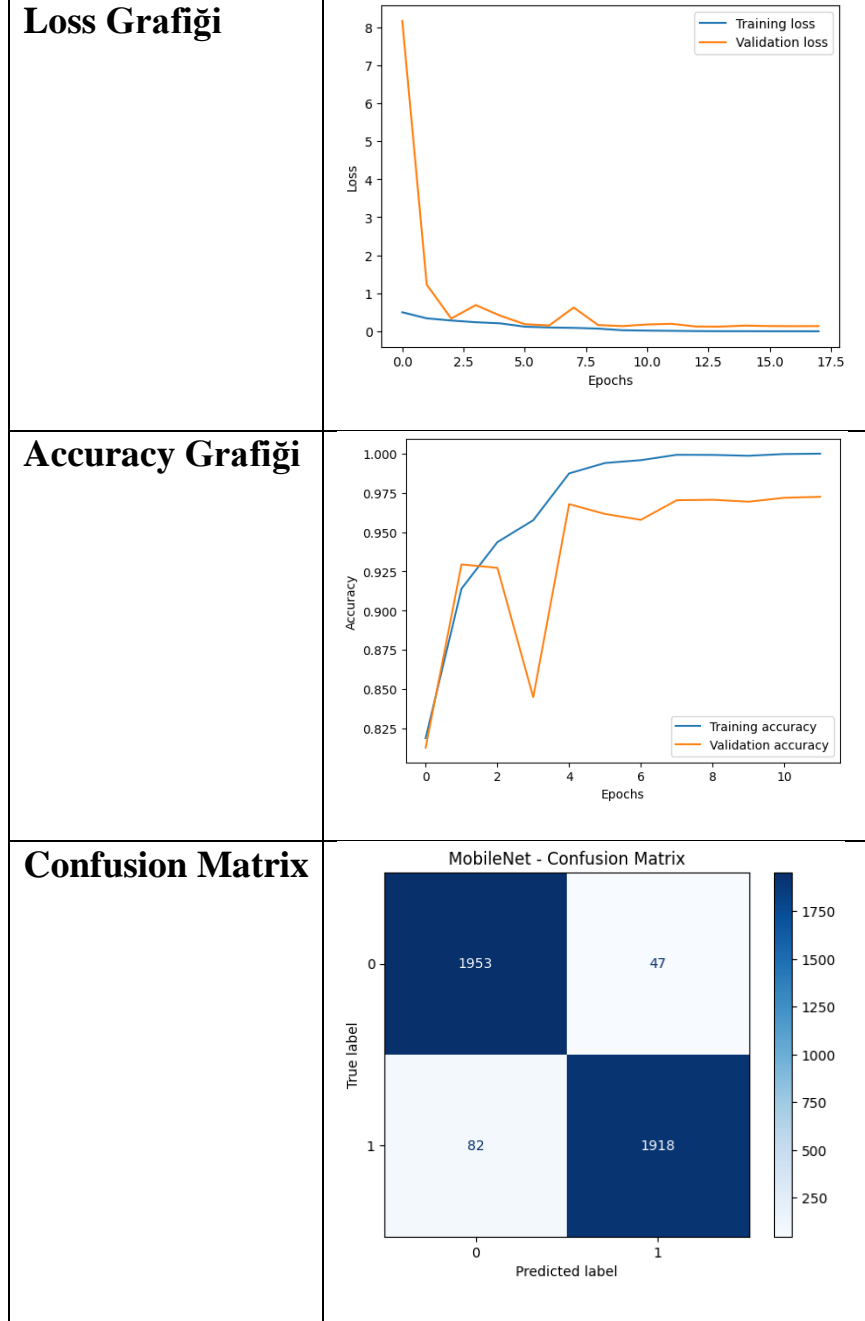
Confusion matrix değerlendirmesinde, modelin 2000 örnek üzerinden 1939 negatif örneği ve 1911 pozitif örneği doğru sınıflandırdığı görülmektedir. Yanlış sınıflandırılan örnek sayısı oldukça düşüktür (yalnızca 150 civarı), bu da modelin genel başarı düzeyinin yüksek olduğunu ortaya koymaktadır.

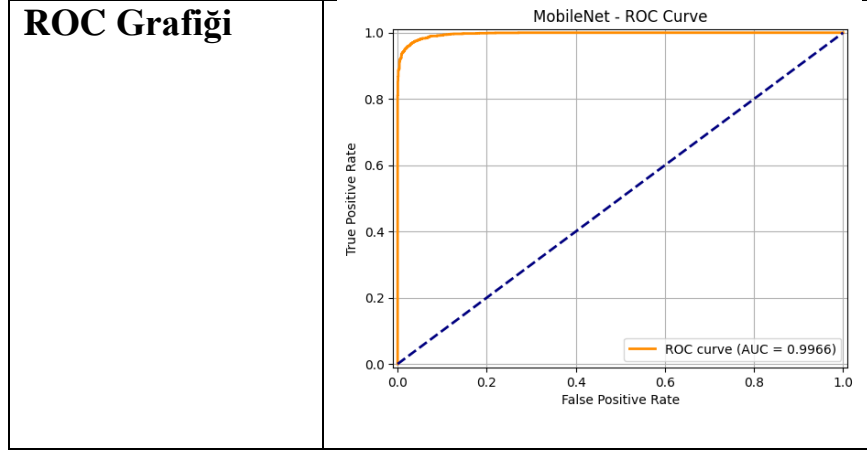
ROC eğrisi ve AUC değeri, modelin sınıflar arası ayırım yapma yeteneğini ölçmek açısından önemlidir. Tablo 2’de yer alan ROC Grafiğinde, AUC değeri 0.9942 olarak hesaplanmıştır. Bu değer, modelin neredeyse kusursuz bir ayırt ediciliğe sahip olduğunu ortaya koymaktadır.

Sonuç olarak, DenseNet121 modeli; doğruluk, kayıp, AUC ve karmaşıklık matrisi açısından değerlendirildiğinde oldukça başarılı bir performans sergilemiş ve medikal görüntü

sınıflandırması için güçlü bir aday olduğunu kanıtlamıştır. Bu modelin, sınıflandırma görevlerinde yüksek genel doğruluk ve düşük hata oranı sunması, gerçek dünya klinik uygulamaları için umut verici sonuçlar doğurmuştur.

4.1.5 MobileNet





Tablo 4.6: MobileNet Test Sonuçları

Tablo 6’da gösterilen MobileNet modeline ait eğitim ve doğrulama kaybı Grafiğinde, eğitim kaybının düzenli bir biçimde azaldığı; doğrulama kaybının ise ilk epoch’larda dalgalı bir seyir izledikten sonra belirgin biçimde düştüğü gözlemlenmiştir. Bu durum, modelin zamanla genelleme yeteneğini artırdığını ve overfitting eğiliminin kontrol altında tutulduğunu göstermektedir.


Aynı tabloya ait doğruluk Grafiğinde, eğitim doğruluğunun yaklaşık %100 seviyelerine kadar ulaştığı ve doğrulama doğruluğunun da %97 düzeyine sabitlendiği görülmektedir. Bu da modelin yüksek performanslı bir sınıflandırıcı olarak çalıştığını ortaya koymaktadır.

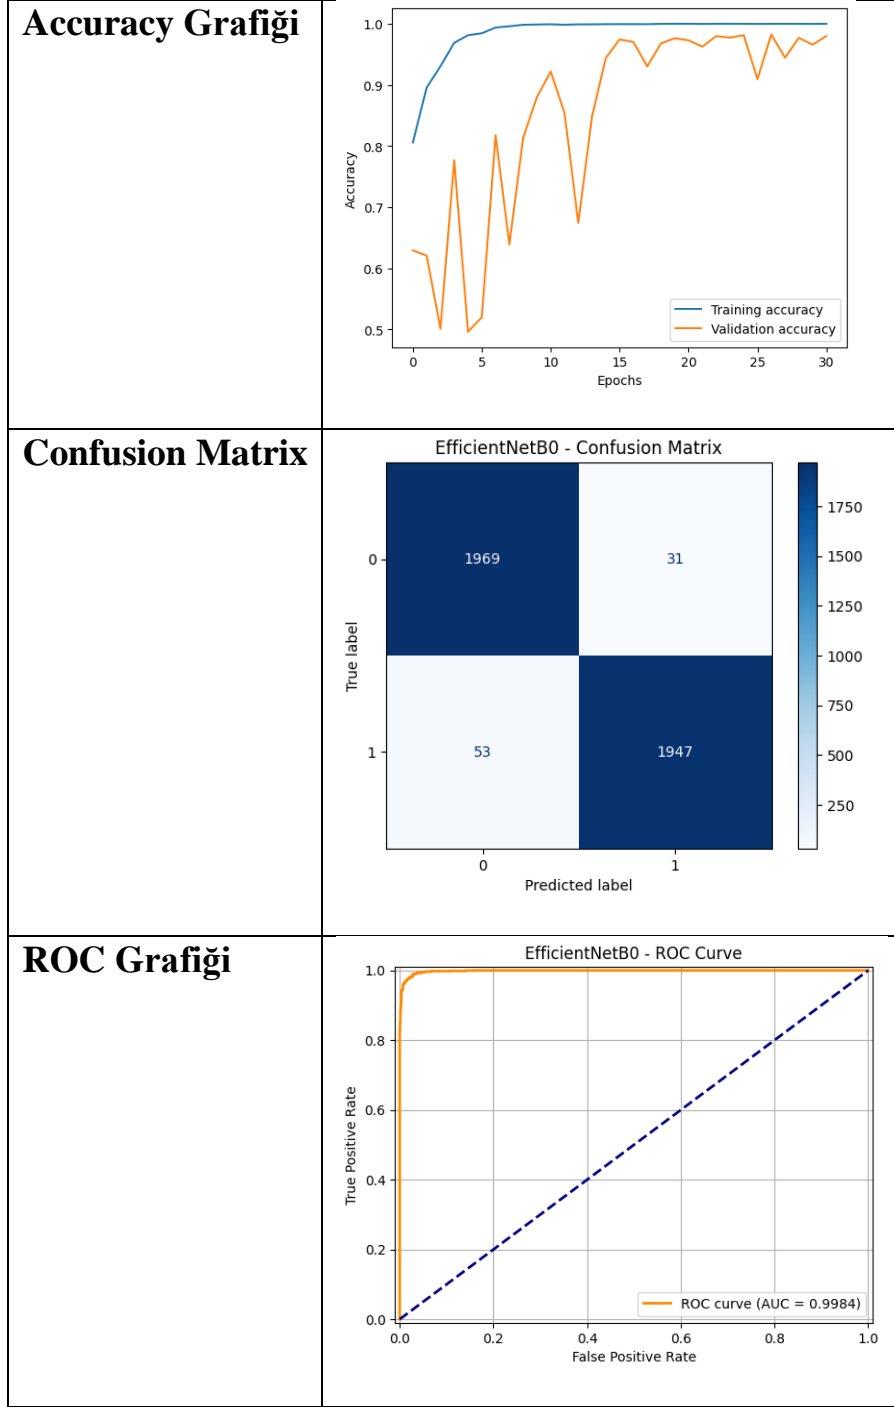
MobileNet’e ait karmaşıklık matrisi incelendiğinde, modelin 1953 adet gerçek negatif ve 1918 adet gerçek pozitif örneği doğru sınıflandırdığı görülmektedir. Buna karşın 47 adet negatif örneği yanlışlıkla pozitif ve 82 pozitif örneği de negatif olarak tahmin etmiştir. Bu dağılım, sınıflar arasında oldukça dengeli ve düşük hatayla çalışan bir model yapısını işaret etmektedir.

Ayrıca, aynı tablo içinde sunulan ROC eğrisinde, AUC değerinin 0.9966 olduğu görülmektedir. Bu değer, MobileNet modelinin sınıflar arasında ayırt etme gücünün oldukça yüksek olduğunu ve genel doğruluk dışında da güvenilir tahminler sunduğunu doğrulamaktadır.

Sonuç olarak, MobileNet modeli, düşük eğitim ve validasyon kaybı, yüksek doğruluk, dengeli hata dağılımı ve güçlü ROC-AUC performansı ile meningeoma sınıflandırmasında oldukça başarılı bir mimari olarak değerlendirilmiştir.

4.1.6 EfficientNetB0





Tablo 4.7: EfficientNetB0 Modeli Test Sonuđları

EfficientNetB0 modeli için elde edilen deđerlendirme metriklerine iliřkin gorselleřtirmeler Tablo 7’de sunulmuřtur. Bu tablo dođrultusunda modelin bařarımı ařađıdaki gibi ozetlenebilir:

Eđitim ve dođrulama kayıplarını gosteren grafikte, modelin eđitim verisi uzerinde oldukça hızlı bir řekilde duřuk kayıplara ulařtıđı gorumektedir. Validation loss bařlangıçta yuksek dalgalanmalar sergilese de yaklařık 10. epoch sonrası dengelenmiř ve duřuř eđilimi gostermiřtir. Bu durum, modelin overfitting eđilimi gostermediđini ve genel performansının istikrarlı hale geldiđini iřaret etmektedir.

Doğruluk Grafiği incelendiğinde, eğitim doğruluğunun hızlı şekilde %100'e yakınsadığı, doğrulama doğruluğunun ise yaklaşık %97 civarında sabitlendiği gözlemlenmektedir. Bu durum, modelin yüksek başarı oranı ile genellenebilir sonuçlar üretebildiğini göstermektedir.

Confusion matrix'e göre model, 1969 adet Tipik ve 1947 adet Non-Tipik vakayı doğru sınıflandırmıştır. Yanlış sınıflandırılan örnek sayıları oldukça düşük düzeydedir (sırasıyla 31 ve 53), bu da sınıflar arası ayırım başarısının oldukça yüksek olduğunu göstermektedir.

ROC eğrisi altında kalan alan AUC değeri 0.9984 olarak ölçülmüştür. Bu sonuç, modelin pozitif ve negatif sınıflar arasında oldukça başarılı bir ayırım yaptığını ve genel sınıflandırma kapasitesinin çok yüksek olduğunu göstermektedir.

Sonuç olarak, EfficientNetB0 modeli; hem eğitim hem de doğrulama üzerinde istikrarlı bir öğrenme eğrisi sergilemiş, sınıflandırma başarımı yüksek çıkmış ve doğrulama sırasında da kararlı performans sunarak etkili bir alternatif olduğunu kanıtlamıştır. Bu performans, onu meningeoma sınıflandırması gibi medikal görüntüleme problemleri için güçlü aday modellerden biri haline getirmektedir.

4.2 TÜM MODELLERİN KARŞILAŞTIRILMALI SONUÇ KISMI

Tablo 8'de sunulan, bu çalışmada meningeoma sınıflandırması için kullanılan tüm derin öğrenme mimarilerinin karşılaştırmalı performans sonuçlarını özetlemektedir. Her bir model; doğruluk , kesinlik , duyarlılık , özgüllük ve F1-Skoru açısından değerlendirilmiştir.

Model Name	Accuracy	Precision	Recall	Specificity	F1-Score
Xception	98.83%	98.70%	98.95%	98.70%	98.82%
Resnet	91.90%	89.48%	94.95%	88.85%	92.13%
InceptionV3	96.40%	95.58%	97.30%	95.50%	96.43%
DenseNet	96.25%	95.61%	96.95%	95.55%	96.28%
MobileNet	96.78%	95.97%	95.97%	95.90%	96.80%
EfficientNetB0	97.90%	97.38%	98.45%	97.35%	97.91%

Tablo 4.8: Tüm Modellerin Sınıflandırma Test Sonuçlarının Karşılaştırılması

Tablo 8 incelendiğinde, Xception modeli %98,83 doğruluk ve %98.82 F1-Skoru ile en yüksek genel performansı sergilemiştir. Özellikle %98.95 gibi oldukça yüksek bir duyarlılık oranına ulaşması, modelin tümörlü örnekleri başarılı şekilde sınıflandırabildiğini göstermektedir. Ayrıca özgüllük değeri de %98.70 ile dengesiz sınıflar arasında güçlü bir ayırım yapılabildiğini ortaya koymaktadır.

EfficientNetB0 modeli, %97.90 doğruluk ve %97.91 F1-Skoru ile Xception modelini çok yakından takip etmektedir. Modelin duyarlılığı %98.45 ile en yüksek seviyede olup, hata toleransının düşük olduğu medikal sistemlerde önemli bir avantaj sağlamaktadır.

MobileNetV2, hafif yapısına rağmen %96.78 doğruluk ve %96.80 F1 skoru ile dikkat çekici sonuçlar üretmiş, özellikle düşük kaynak tüketimi gerektiren uygulamalar için etkili bir alternatif olduğunu kanıtlamıştır.

InceptionV3 ve DenseNet121, benzer doğruluk ve F1 skorlarıyla %96 seviyelerinde yer almış; her iki model de denge ve genellenebilirlik açısından başarılı sonuçlar vermiştir.

ResNet50 modeli ise diğer modellere kıyasla daha düşük bir doğruluk (%91.90) ve F1 skoru (%92.13) üretmiş, ancak %94.95 gibi yüksek bir duyarlılık ile tümör tespiti konusunda başarılı bir tablo çizmiştir. Bununla birlikte düşük özgüllük değeri (%88.85), bazı normal görüntülerin yanlış pozitif olarak sınıflandırıldığını göstermektedir.

Sonuç olarak, Xception ve EfficientNetB0 modelleri, meningeoma sınıflandırması bağlamında en güçlü performansı sunmuş; bu durum ROC-AUC değerleri, confusion matrix analizleri ve eğitim/validasyon eğrileri ile de desteklenmiştir. Bu modeller, medikal teşhis sistemlerinde doğruluk ve güvenilirlik açısından öne çıkmaktadır.

5. TARTIŞMA VE SONUÇ

Bu çalışmada, MRI verilerini temel alan, DICOM formatında yüklenen tıbbi görüntüler üzerinden çalışan ve yapay zeka destekli sınıflandırma gerçekleştiren bir karar destek sistemi geliştirilmiştir. Sistemin temel amacı, beyin tümörlerinin sınıflandırılmasına yardımcı olarak, uzmanların klinik süreçte hızlı ve güvenilir ön analizler yapabilmesine olanak sağlamaktır.

Geliştirilen model, tipik ve atipik tümör sınıflarını yüksek doğruluk oranı ile ayırt edebilmiş ve bu yönüyle özellikle karar destek mekanizmaları açısından önemli bir potansiyel sergilemiştir. Sistem, DICOM verisinin otomatik olarak okunması, ön işlenmesi ve sınıflandırma sonuçlarının kullanıcıya görsel ve metinsel biçimde sunulması süreçlerini bütünlük bir yapıda sunmaktadır. Bu bütünlük yapı, yalnızca analiz performansı değil, aynı zamanda kullanıcı deneyimi açısından da işlevsel bir bütünlük ortaya koymuştur.

Model, Xception mimarisi kullanılarak eğitilmiş ve %98,82 f1 oranı ile sınıflandırma yapmıştır. ROC AUC değeri 0.99 olarak hesaplanmış, bu da modelin sınıflar arasında ayırım yapma başarısının oldukça yüksek olduğunu göstermektedir. Tipik sınıflar genellikle belirgin morfolojik özellikler taşırken, atipik sınıflar daha karmaşık ve çeşitli varyasyonlar göstermekte olup model bu iki sınıfı etkili bir şekilde ayırt edebilmiştir.

Literatürde yapılan benzer çalışmalarda, çoğunlukla 3D-CNN, VGGNet, EfficientNet gibi derin öğrenme mimarileri kullanılarak yüksek doğruluklar elde edilmiştir. Ancak bu çalışmalarda sıklıkla yüksek sayıda örnek içeren ve veri artırımı teknikleri uygulanan geniş veri setleri tercih edilmiştir. Bu bağlamda, bu projede kullanılan yaklaşık 20.000 görüntülük özgün veri seti ve sadeleştirilmiş sınıflandırma yaklaşımıyla elde edilen performans, hem modelin optimizasyon gücünü hem de sistemin ölçeklenebilirliğini ortaya koymaktadır.

Sonuç olarak, geliştirilen yapay zeka destekli sınıflandırma sistemi, beyin tümörü analizlerinde erken ön değerlendirme sürecine katkı sunabilecek düzeydedir. Gelecek çalışmalarda, sistemin doğruluğu ve işlevselliği; segmentasyon, çok sınıflı sınıflandırma, farklı modalite desteği ve hekim geri bildirimleriyle birlikte sürekli geliştirilerek artırılabilir. Ayrıca modelin gerçek zamanlı çalışma kapasitesine uygun hale getirilmesi ve farklı sağlık kurumlarında entegrasyonu üzerine çalışmalar yapılması da önerilmektedir.

KAYNAKLAR

- [1] D. N. Louis *et al.*, ‘The 2021 WHO Classification of Tumors of the Central Nervous System: a summary,’ *Neuro Oncol*, vol. 23, no. 8, pp. 1231–1251, Aug. 2021, doi: 10.1093/neuonc/noab106.
- [2] S. U. K. Bukhari, A. Syed, S. K. A. Bokhari, and S. S. H. Shah, ‘The efficiency of deep learning for the diagnosis of psammomatous meningioma,’ *Annals of Clinical and Analytical Medicine*, vol. 12, no. 02, pp. 153–156, Feb. 2021, doi: 10.4328/ACAM.20226.
- [3] T. Banzato, F. Causin, A. Della Puppa, G. Cester, L. Mazzai, and A. Zotti, ‘Accuracy of deep learning to differentiate the histopathological grading of meningiomas on MR images: A preliminary study,’ *Journal of Magnetic Resonance Imaging*, vol. 50, no. 4, pp. 1152–1159, Oct. 2019, doi: 10.1002/jmri.26723.
- [4] Y. Lu, L. Liu, S. Luan, J. Xiong, D. Geng, and B. Yin, ‘The diagnostic value of texture analysis in predicting WHO grades of meningiomas based on ADC maps: an attempt using decision tree and decision forest,’ *Eur Radiol*, vol. 29, no. 3, pp. 1318–1328, Mar. 2019, doi: 10.1007/s00330-018-5632-7.
- [5] C. L. M. Morais *et al.*, ‘Determination of meningioma brain tumour grades using Raman microspectroscopy imaging,’ *Analyst*, vol. 144, no. 23, pp. 7024–7031, 2019, doi: 10.1039/C9AN01551E.
- [6] N. Li, X. Liu, X. Xia, X. Liu, G. Wang, and C. Duan, ‘An MRI-based deep transfer learning radiomics nomogram for predicting meningioma grade,’ *Sci Rep*, vol. 15, no. 1, p. 16614, May 2025, doi: 10.1038/s41598-025-01665-0.
- [7] P. S. Foundation, ‘Python 3.12 Documentation.’
- [8] FastAPI, ‘FastAPI documentation.’
- [9] TensorFlow, ‘TensorFlow Core documentation.’
- [10] Keras, ‘Keras API documentation.’
- [11] D. Mason, ‘Pydicom documentation.’
- [12] U. Team, ‘Uvicorn Documentation.’
- [13] G. SCM, ‘Git Documentation.’
- [14] M. (Facebook), ‘React documentation.’
- [15] Microsoft, ‘TypeScript Documentation.’
- [16] C. UI, ‘Chakra UI documentation.’
- [17] A. P. Contributors, ‘Axios Documentation.’
- [18] Z. Developers, ‘Zustand Documentation.’

- [19] Y. LeCun, Y. Bengio, and G. Hinton, ‘Deep learning,’ *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [20] F. Rosenblatt, ‘The perceptron: A probabilistic model for information storage and organization in the brain.,’ *Psychol Rev*, vol. 65, no. 6, pp. 386–408, 1958, doi: 10.1037/h0042519.
- [21] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. The MIT Press, 2016.
- [22] José Daniel Reis Junior, Ana Maria Ambrosio, and Fabiano Luis de Sousa, ‘Towards Spacecraft Real-Time Thermal Simulation with Artificial Neural Networks,’ 2015. doi: 10.20906/CPS/COB-2015-0316.
- [23] X. Glorot, A. Bordes, and Y. Bengio, ‘Deep Sparse Rectifier Neural Networks,’ in *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, G. Gordon, D. Dunson, and M. Dudík, Eds., in Proceedings of Machine Learning Research, vol. 15. Fort Lauderdale, FL, USA: PMLR, May 2011, pp. 315–323. [Online]. Available: <https://proceedings.mlr.press/v15/glorot11a.html>
- [24] K. Hornik, ‘Approximation capabilities of multilayer feedforward networks,’ *Neural Networks*, vol. 4, no. 2, pp. 251–257, 1991, doi: [https://doi.org/10.1016/0893-6080\(91\)90009-T](https://doi.org/10.1016/0893-6080(91)90009-T).
- [25] S. Hochreiter, ‘The Vanishing Gradient Problem During Learning Recurrent Neural Nets and Problem Solutions,’ *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, vol. 06, no. 02, pp. 107–116, Apr. 1998, doi: 10.1142/S0218488598000094.
- [26] V. Nair and G. E. Hinton, ‘Rectified linear units improve restricted boltzmann machines,’ in *Proceedings of the 27th International Conference on International Conference on Machine Learning*, in ICML’10. Madison, WI, USA: Omnipress, 2010, pp. 807–814.
- [27] K. Fukushima, ‘Training multi-layered neural network neocognitron,’ *Neural Networks*, vol. 40, pp. 18–31, 2013, doi: <https://doi.org/10.1016/j.neunet.2013.01.001>.
- [28] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, ‘Gradient-based learning applied to document recognition,’ *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998, doi: 10.1109/5.726791.
- [29] D. Scherer, A. Müller, and S. Behnke, ‘Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition,’ 2010, pp. 92–101. doi: 10.1007/978-3-642-15825-4_10.
- [30] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, ‘Learning representations by back-propagating errors,’ *Nature*, vol. 323, no. 6088, pp. 533–536, Oct. 1986, doi: 10.1038/323533a0.
- [31] L. Bottou, ‘Large-Scale Machine Learning with Stochastic Gradient Descent,’ in *Proceedings of COMPSTAT’2010*, Heidelberg: Physica-Verlag HD, 2010, pp. 177–186. doi: 10.1007/978-3-7908-2604-3_16.

- [32] D. P. Kingma and J. Ba, ‘Adam: A Method for Stochastic Optimization,’ Dec. 2014.
- [33] L. Prechelt, ‘Automatic early stopping using cross validation: quantifying the criteria,’ *Neural Networks*, vol. 11, no. 4, pp. 761–767, Jun. 1998, doi: 10.1016/S0893-6080(98)00010-0.
- [34] F. Chollet, ‘Xception: Deep Learning with Depthwise Separable Convolutions,’ in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jul. 2017, pp. 1800–1807. doi: 10.1109/CVPR.2017.195.
- [35] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, ‘Dropout: a simple way to prevent neural networks from overfitting,’ *J. Mach. Learn. Res.*, vol. 15, no. 1, pp. 1929–1958, Jan. 2014.
- [36] B. Gülmez, ‘A novel deep neural network model based Xception and genetic algorithm for detection of COVID-19 from X-ray images,’ *Ann Oper Res*, vol. 328, no. 1, pp. 617–641, Sep. 2023, doi: 10.1007/s10479-022-05151-y.
- [37] K. He, X. Zhang, S. Ren, and J. Sun, ‘Deep Residual Learning for Image Recognition,’ in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun. 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [38] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, ‘Rethinking the Inception Architecture for Computer Vision,’ Dec. 2015.
- [39] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, ‘Densely Connected Convolutional Networks,’ in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jul. 2017, pp. 2261–2269. doi: 10.1109/CVPR.2017.243.
- [40] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, ‘MobileNetV2: Inverted Residuals and Linear Bottlenecks,’ Jan. 2018.
- [41] M. Tan and Q. V. Le, ‘EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,’ May 2019.
- [42] M. S. Başarslan and M. Z. Khaliki, ‘Brain tumor detection from images and comparison with transfer learning methods and 3-layer CNN,’ *Sci Rep*, vol. 14, no. 1, p. 2664, Feb. 2024, doi: 10.1038/s41598-024-52823-9.

EKLER

EK 1

Veriler, danışman hocamız Muhammet Sinan BAŞARSLAN ve proje süreci başvurusu devam ettiği TÜBİTAK proje süreçlerin görev alan Beyin Cerrahı Dr. Mustafa Umut Etili hoca önderliğinde toplanmıştır. Etik beyanı aşağıdaki verilmiştir.

İSTANBUL EĞİTİM VE ARAŞTIRMA HASTANESİ
KULÜBÜNE GİRİŞ BİNGİ
İSTANBUL SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
EĞİTİM VE ARAŞTIRMA HASTANESİ
EĞİLİM VE YÖNLENDİRME BİRİMİ
10.001-10.002-10.003-10.004-10.005-10.006-10.007-10.008-10.009-10.010-10.011-10.012-10.013-10.014-10.015-10.016-10.017-10.018-10.019-10.020-10.021-10.022-10.023-10.024-10.025-10.026-10.027-10.028-10.029-10.030-10.031-10.032-10.033-10.034-10.035-10.036-10.037-10.038-10.039-10.040-10.041-10.042-10.043-10.044-10.045-10.046-10.047-10.048-10.049-10.050-10.051-10.052-10.053-10.054-10.055-10.056-10.057-10.058-10.059-10.060-10.061-10.062-10.063-10.064-10.065-10.066-10.067-10.068-10.069-10.070-10.071-10.072-10.073-10.074-10.075-10.076-10.077-10.078-10.079-10.080-10.081-10.082-10.083-10.084-10.085-10.086-10.087-10.088-10.089-10.090-10.091-10.092-10.093-10.094-10.095-10.096-10.097-10.098-10.099-10.100-10.101-10.102-10.103-10.104-10.105-10.106-10.107-10.108-10.109-10.110-10.111-10.112-10.113-10.114-10.115-10.116-10.117-10.118-10.119-10.120-10.121-10.122-10.123-10.124-10.125-10.126-10.127-10.128-10.129-10.130-10.131-10.132-10.133-10.134-10.135-10.136-10.137-10.138-10.139-10.140-10.141-10.142-10.143-10.144-10.145-10.146-10.147-10.148-10.149-10.150-10.151-10.152-10.153-10.154-10.155-10.156-10.157-10.158-10.159-10.160-10.161-10.162-10.163-10.164-10.165-10.166-10.167-10.168-10.169-10.170-10.171-10.172-10.173-10.174-10.175-10.176-10.177-10.178-10.179-10.180-10.181-10.182-10.183-10.184-10.185-10.186-10.187-10.188-10.189-10.190-10.191-10.192-10.193-10.194-10.195-10.196-10.197-10.198-10.199-10.200-10.201-10.202-10.203-10.204-10.205-10.206-10.207-10.208-10.209-10.210-10.211-10.212-10.213-10.214-10.215-10.216-10.217-10.218-10.219-10.220-10.221-10.222-10.223-10.224-10.225-10.226-10.227-10.228-10.229-10.230-10.231-10.232-10.233-10.234-10.235-10.236-10.237-10.238-10.239-10.240-10.241-10.242-10.243-10.244-10.245-10.246-10.247-10.248-10.249-10.250-10.251-10.252-10.253-10.254-10.255-10.256-10.257-10.258-10.259-10.260-10.261-10.262-10.263-10.264-10.265-10.266-10.267-10.268-10.269-10.270-10.271-10.272-10.273-10.274-10.275-10.276-10.277-10.278-10.279-10.280-10.281-10.282-10.283-10.284-10.285-10.286-10.287-10.288-10.289-10.290-10.291-10.292-10.293-10.294-10.295-10.296-10.297-10.298-10.299-10.300-10.301-10.302-10.303-10.304-10.305-10.306-10.307-10.308-10.309-10.310-10.311-10.312-10.313-10.314-10.315-10.316-10.317-10.318-10.319-10.320-10.321-10.322-10.323-10.324-10.325-10.326-10.327-10.328-10.329-10.330-10.331-10.332-10.333-10.334-10.335-10.336-10.337-10.338-10.339-10.340-10.341-10.342-10.343-10.344-10.345-10.346-10.347-10.348-10.349-10.350-10.351-10.352-10.353-10.354-10.355-10.356-10.357-10.358-10.359-10.360-10.361-10.362-10.363-10.364-10.365-10.366-10.367-10.368-10.369-10.370-10.371-10.372-10.373-10.374-10.375-10.376-10.377-10.378-10.379-10.380-10.381-10.382-10.383-10.384-10.385-10.386-10.387-10.388-10.389-10.390-10.391-10.392-10.393-10.394-10.395-10.396-10.397-10.398-10.399-10.400-10.401-10.402-10.403-10.404-10.405-10.406-10.407-10.408-10.409-10.410-10.411-10.412-10.413-10.414-10.415-10.416-10.417-10.418-10.419-10.420-10.421-10.422-10.423-10.424-10.425-10.426-10.427-10.428-10.429-10.430-10.431-10.432-10.433-10.434-10.435-10.436-10.437-10.438-10.439-10.440-10.441-10.442-10.443-10.444-10.445-10.446-10.447-10.448-10.449-10.450-10.451-10.452-10.453-10.454-10.455-10.456-10.457-10.458-10.459-10.460-10.461-10.462-10.463-10.464-10.465-10.466-10.467-10.468-10.469-10.470-10.471-10.472-10.473-10.474-10.475-10.476-10.477-10.478-10.479-10.480-10.481-10.482-10.483-10.484-10.485-10.486-10.487-10.488-10.489-10.490-10.491-10.492-10.493-10.494-10.495-10.496-10.497-10.498-10.499-10.500-10.501-10.502-10.503-10.504-10.505-10.506-10.507-10.508-10.509-10.510-10.511-10.512-10.513-10.514-10.515-10.516-10.517-10.518-10.519-10.520-10.521-10.522-10.523-10.524-10.525-10.526-10.527-10.528-10.529-10.530-10.531-10.532-10.533-10.534-10.535-10.536-10.537-10.538-10.539-10.540-10.541-10.542-10.543-10.544-10.545-10.546-10.547-10.548-10.549-10.550-10.551-10.552-10.553-10.554-10.555-10.556-10.557-10.558-10.559-10.560-10.561-10.562-10.563-10.564-10.565-10.566-10.567-10.568-10.569-10.570-10.571-10.572-10.573-10.574-10.575-10.576-10.577-10.578-10.579-10.580-10.581-10.582-10.583-10.584-10.585-10.586-10.587-10.588-10.589-10.590-10.591-10.592-10.593-10.594-10.595-10.596-10.597-10.598-10.599-10.600-10.601-10.602-10.603-10.604-10.605-10.606-10.607-10.608-10.609-10.610-10.611-10.612-10.613-10.614-10.615-10.616-10.617-10.618-10.619-10.620-10.621-10.622-10.623-10.624-10.625-10.626-10.627-10.628-10.629-10.630-10.631-10.632-10.633-10.634-10.635-10.636-10.637-10.638-10.639-10.640-10.641-10.642-10.643-10.644-10.645-10.646-10.647-10.648-10.649-10.650-10.651-10.652-10.653-10.654-10.655-10.656-10.657-10.658-10.659-10.660-10.661-10.662-10.663-10.664-10.665-10.666-10.667-10.668-10.669-10.670-10.671-10.672-10.673-10.674-10.675-10.676-10.677-10.678-10.679-10.680-10.681-10.682-10.683-10.684-10.685-10.686-10.687-10.688-10.689-10.690-10.691-10.692-10.693-10.694-10.695-10.696-10.697-10.698-10.699-10.700-10.701-10.702-10.703-10.704-10.705-10.706-10.707-10.708-10.709-10.710-10.711-10.712-10.713-10.714-10.715-10.716-10.717-10.718-10.719-10.720-10.721-10.722-10.723-10.724-10.725-10.726-10.727-10.728-10.729-10.730-10.731-10.732-10.733-10.734-10.735-10.736-10.737-10.738-10.739-10.740-10.741-10.742-10.743-10.744-10.745-10.746-10.747-10.748-10.749-10.750-10.751-10.752-10.753-10.754-10.755-10.756-10.757-10.758-10.759-10.760-10.761-10.762-10.763-10.764-10.765-10.766-10.767-10.768-10.769-10.770-10.771-10.772-10.773-10.774-10.775-10.776-10.777-10.778-10.779-10.780-10.781-10.782-10.783-10.784-10.785-10.786-10.787-10.788-10.789-10.790-10.791-10.792-10.793-10.794-10.795-10.796-10.797-10.798-10.799-10.800-10.801-10.802-10.803-10.804-10.805-10.806-10.807-10.808-10.809-10.810-10.811-10.812-10.813-10.814-10.815-10.816-10.817-10.818-10.819-10.820-10.821-10.822-10.823-10.824-10.825-10.826-10.827-10.828-10.829-10.830-10.831-10.832-10.833-10.834-10.835-10.836-10.837-10.838-10.839-10.840-10.841-10.842-10.843-10.844-10.845-10.846-10.847-10.848-10.849-10.850-10.851-10.852-10.853-10.854-10.855-10.856-10.857-10.858-10.859-10.860-10.861-10.862-10.863-10.864-10.865-10.866-10.867-10.868-10.869-10.870-10.871-10.872-10.873-10.874-10.875-10.876-10.877-10.878-10.879-10.880-10.881-10.882-10.883-10.884-10.885-10.886-10.887-10.888-10.889-10.890-10.891-10.892-10.893-10.894-10.895-10.896-10.897-10.898-10.899-10.900-10.901-10.902-10.903-10.904-10.905-10.906-10.907-10.908-10.909-10.910-10.911-10.912-10.913-10.914-10.915-10.916-10.917-10.918-10.919-10.920-10.921-10.922-10.923-10.924-10.925-10.926-10.927-10.928-10.929-10.930-10.931-10.932-10.933-10.934-10.935-10.936-10.937-10.938-10.939-10.940-10.941-10.942-10.943-10.944-10.945-10.946-10.947-10.948-10.949-10.950-10.951-10.952-10.953-10.954-10.955-10.956-10.957-10.958-10.959-10.960-10.961-10.962-10.963-10.964-10.965-10.966-10.967-10.968-10.969-10.970-10.971-10.972-10.973-10.974-10.975-10.976-10.977-10.978-10.979-10.980-10.981-10.982-10.983-10.984-10.985-10.986-10.987-10.988-10.989-10.990-10.991-10.992-10.993-10.994-10.995-10.996-10.997-10.998-10.999-11.000

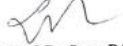
**T.C.
SAĞLIK BAKANLIĞI
İSTANBUL SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
Ümraniye Eğitim ve Araştırma Hastanesi
Klinik Araştırmalar Etik Kurulu**

Sayı : B.10.1.TKH.4.34.H.GP.0.01/ 307
Konu : Onay Yazısı

**HASTANE BAŞHEKİMLİĞİNE
(Uzm. Dr. Eyüp VAROL'a İletilmek Üzere)**

05/10/2023 tarihinde yapılan Ümraniye Eğitim Araştırma Hastanesi Klinik Araştırmalar Etik Kurul toplantısında " Spontan Subaraknoid Kanama Hastalarında Yapay Zeka Yöntemlerinin Kullanımı" isimli çalışmamızın gerçekleştirilmesinde etik açıdan bir sakınca olmadığına oy çokluğu ile karar verilmiştir.

Gereğini bilgilerinize arz ederim.


**Prof. Dr. Sema BASAT
ETİK KURUL BAŞKANI**

Ek1:Form(2 sayfa)

**T.C.
SAĞLIK BAKANLIĞI
İSTANBUL SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
Ümraniye Eğitim ve Araştırma Hastanesi
Klinik Araştırmalar Etik Kurulu**

Ümraniye Eğitim ve Araştırma Hastanesi.
Adres: Elmalkent Mahallesi, Adem Yavuz Caddesi, No:1 PK. 34760 Ümraniye/ İSTANBUL
Tel: (0216) 632 18 18/11 64 Faks: (0216) 632 71 21-24

ASLI GİLELİDİR