

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI
BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ ANABİLİM
DALI

MASKELENMİŞ MR GÖRÜNTÜLERİNDEN ÖNCEDEN
EĞİTİLMİŞ TRANSFER ÖĞRENME YÖNTEMLERİ
KULLANILARAK BEYİN TÜMÖRLERİNİN
SINIFLANDIRILMASI

DOKTORA TEZİ

Ayşenur TOPBAŞ

İstanbul,

Ekim-2025

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI
BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ ANABİLİM
DALI

MASKELENMİŞ MR GÖRÜNTÜLERİNDEN ÖNCEDEN
EĞİTİLMİŞ TRANSFER ÖĞRENME YÖNTEMLERİ
KULLANILARAK BEYİN TÜMÖRLERİNİN
SINIFLANDIRILMASI

DOKTORA TEZİ

Ayşenur TOPBAŞ

Tez Danışmanı

Dr. Öğr. Üyesi Sümeyra BEDİR

İstanbul,

Ekim-2025

Lisansüstü Eğitim Enstitüsü Müdürlüğüne,

Bu çalışma, jürimiz tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Bilimleri ve Mühendisliği (%30 İngilizce) Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman Dr. Öğr. Üyesi Sümeyra BEDİR (Islak İmza)

Üye Dr. Öğr. Üyesi Şengül BAYRAK (Islak İmza)

Üye Dr. Öğr. Üyesi Muhammed DAVUD (Islak İmza)

Üye Dr. Öğr. Üyesi Hakan GENÇOĞLU (Islak İmza)

Üye Dr. Öğr. Üyesi Kevser Nur ÇOĞALMIŞ (Islak İmza)

Onay

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

Islak İmza

Prof. Dr. Erhan İÇENER

Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİMİ

Doktora tezi olarak hazırladığım “**Maskelenmiş MR Görüntülerinden Önceden Eğitilmiş Transfer Öğrenme Yöntemleri Kullanılarak Beyin Tümörlerinin Sınıflandırılması**” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

Ayşenur TOPBAŞ

ÖN SÖZ

Araştırmamın ve yazım sürecimin her aşamasında desteğini esirgemeyen; bilgi ve tecrübesinden daima yararlandığım, yönlendirmeleriyle farklı bakış açıları kazanmama katkı sağlayan ve projeyi şekillendirmemde büyük rol oynayan değerli tez danışmanım Dr. Öğr. Üyesi Sümeyra BEDİR'e, çok sevdiğim çalışma arkadaşlarıma, bu zorlu süreçte sabrıyla, sevgisiyle ve desteğiyle her zaman yanımda olan sevgili eşim Mükremin TOPBAŞ'a, canım oğlum Muhammed Eren TOPBAŞ'a ve beni bu günlere getiren değerli aileme en içten teşekkürlerimi sunuyorum. Doktora tezimi, belki de bu hayatta doktor olmamı en çok isteyen ama maalesef bu günleri göremeyen canım babaanneme ithaf ediyorum.

Ayşenur TOPBAŞ

İstanbul-2025

ÖZET

MASKELENMİŞ MR GÖRÜNTÜLERİNDEN ÖNCEDEN EĞİTİLMİŞ TRANSFER ÖĞRENME YÖNTEMLERİ KULLANILARAK BEYİN TÜMÖRLERİNİN SINIFLANDIRILMASI

Ayşenur TOPBAŞ

Doktora, Bilgisayar Bilimleri ve Mühendisliği (%30 İngilizce)

Tez Danışmanı: Dr. Öğr. Üyesi Sümeyra BEDİR

Ekim, 2025 - 113 + xvii Sayfa

Beyin tümörleri, zamanında teşhis edilmediklerinde ciddi nörolojik hasarlara ve yaşam kaybına neden olabilen hastalıklardır. Bu nedenle, tümörlerin doğru biçimde sınıflandırılması; etkili tedavi stratejilerinin belirlenmesi, hastalığın seyri hakkında doğru öngörülerde bulunulması büyük önem arz etmektedir. Günümüzde tıbbi görüntüleme teknikleri içerisinde manyetik rezonans görüntüleme (MRG) beyin tümörlerinin yapısal özelliklerinin ayrıntılı biçimde değerlendirilmesine olanak tanımakta ve bu özelliği nedeniyle sıklıkla tercih edilmektedir. Bu çalışma kapsamında, dört farklı kategoriye ayrılmış (glioma, meningioma, hipofiz tümörü ve tümör içermeyen) MR görüntüleri üzerinde segmentasyon destekli hibrit derin öğrenme yaklaşımları değerlendirilmiştir. Farklı açık kaynaklardan temin edilen ve aynı formatta yapılandırılan görüntüler birleştirilerek, daha geniş kapsamlı ve sınıf dengesi gözetilmiş bir veri seti oluşturulmuştur. Sınıflandırma aşamasında ise önceden eğitilmiş ResNet50, InceptionNetV3, VGG19, MobileNet ve EfficientNetB3 mimarileri kullanılmış; bu modeller, U-Net mimarisiyle gerçekleştirilen segmentasyon işlemi sonucunda tahmin edilen maskelerle birlikte hibrit yapılar halinde test edilmiştir. Elde edilen deneysel bulgular, sınıflandırma başarısında segmentasyon işlemi sonucunda tahmin edilen maskelerin etkisini açık bir biçimde ortaya koymuştur. Bu sonuç, ön işleme sürecinin doğrudan modelin sınıflandırma performansını ve genelleme yeteneğini artırdığını göstermiştir.

Anahtar Kelimeler: Beyin MR Görüntüleri, Tümör Sınıflandırması, Transfer Öğrenme Modelleri, Görüntü Segmentasyonu, Maskeleye Yöntemi

ABSTRACT

CLASSIFICATION OF BRAIN TUMORS FROM MASKED MR IMAGES USING PRE-TRAINED TRANSFER LEARNING METHODS

Ayşenur TOPBAŞ

Ph. D. Computer Science and Engineering (30% English)

Supervisor: Asst. Prof Dr. Sümeyra BEDİR

October, 2025 – 113 + xvii Pages

Brain tumors are diseases that can cause serious neurological damage and loss of life if not diagnosed in a timely manner. Therefore, accurately classifying tumors, determining effective treatment strategies, and making accurate predictions about the course of the disease are of vital importance. Currently, among medical imaging techniques, magnetic resonance imaging (MRG) allows for detailed assessment of the structural features of brain tumors and is frequently preferred for this reason. In this study, segmentation-based hybrid deep learning approaches were evaluated on MRG images categorized into four different categories (glioma, meningioma, pituitary tumor, and no-tumor). By combining images obtained from different open sources and structured in the same format, a more comprehensive dataset with class balance was created. In the classification phase, pre-trained ResNet50, InceptionV3, VGG19, MobileNet, and EfficientNetB3 architectures were used; these models were tested in hybrid structures with masks estimated from the segmentation process performed with the U-Net architecture. The experimental findings clearly demonstrated the impact of the masks estimated from the segmentation process on classification accuracy. This result showed that the preprocessing process directly increased the classification performance and generalization ability of the model.

Keywords: Brain MRG Images, Tumor Classification, Transfer Learning Models, Image Segmentation, Masking Method

İÇİNDEKİLER

| | |
|---|-------------|
| TEZ ONAYI | i |
| BİLİMSEL ETİK BİLDİRİMİ..... | ii |
| ÖN SÖZ..... | iii |
| ÖZET..... | iv |
| ABSTRACT | v |
| İÇİNDEKİLER | vi |
| TABLolar LİSTESİ..... | ix |
| ŞEKİLLER LİSTESİ..... | xi |
| KISALTMALAR LİSTESİ..... | xvii |
| | |
| BİRİNCİ BÖLÜM | |
| GİRİŞ | 1 |
| 1.1. Problem | 4 |
| 1.2. Amaç | 5 |
| 1.3. Araştırmanın Önemi | 5 |
| 1.4. Sınırlılıklar | 7 |
| | |
| İKİNCİ BÖLÜM | |
| LİTERATÜR TARAMASI | 8 |
| | |
| ÜÇÜNCÜ BÖLÜM | |
| MATERYAL VE YÖNTEMLER..... | 20 |
| 3.1. Veri Seti..... | 20 |
| 3.1.1. Veri Seti Güç Analizi..... | 23 |
| 3.1.2. Veri Artırma Teknikleri | 25 |
| 3.2. Görüntü Maskeleyme Yöntemi | 29 |
| 3.2.1. Sözde (Pseudo) Maskelerin Oluşturulması..... | 30 |

| | |
|--|----|
| 3.2.2 U-Net Tabanlı Segmentasyon Modeli | 33 |
| 3.3. Ön Eğitimli Transfer Öğrenme Modelleri..... | 37 |
| 3.3.1. Residual Network (ResNet50) Modeli | 38 |
| 3.3.2. GoogLeNet mimarisi + Inception modülleri (InceptionNetV3) Modeli .. | 40 |
| 3.3.3. Visual Geometry Group (VGG19) Modeli | 42 |
| 3.3.4. Mobile Networks (MobileNet) Modeli..... | 43 |
| 3.3.5. EfficientNetB3 Modeli | 45 |

DÖRDÜNCÜ BÖLÜM

BULGULAR VE TARTIŞMA

| | |
|---|----|
| 4.1. Önceden Eğitilmiş Derin Öğrenme Modelleri Test Sonuçları | 47 |
| 4.1.1. Residual Network (ResNet50) Modeli Deneysel Sonuçları | 48 |
| 4.1.2. GoogLeNet mimarisi + Inception modülleri (InceptionNetV3) Modeli Deneysel Sonuçları | 51 |
| 4.1.3. Visual Geometry Group (VGG19) Modeli Deneysel Sonuçları..... | 54 |
| 4.1.4. Mobile Networks (MobileNet) Modeli Deneysel Sonuçları..... | 57 |
| 4.1.5. EfficientNetB3 Modeli Deneysel Sonuçları | 60 |
| 4.2. U-Net Segmentasyon İşlemi + Ön Eğitimli Derin Öğrenme Modelleri Deneysel Sonuçları | 63 |
| 4.2.1. U-Net + ResNet50 (Veri Artırmasız) Modeli Deneysel Sonuçları..... | 64 |
| 4.2.2. U-Net + ResNet50 (Artırılmış Veri) Modeli Deneysel Sonuçları | 67 |
| 4.2.3. U-Net + InceptionNetV3 (Veri Artırmasız) Modeli Deneysel Sonuçları. 71 | |
| 4.2.4. U-Net + InceptionNetV3 (Artırılmış Veri) Modeli Deneysel Sonuçları .. | 74 |
| 4.2.5. U-Net + VGG19 (Veri Artırmasız) Modeli Deneysel Sonuçları..... | 77 |
| 4.2.6. U-Net + VGG19 (Artırılmış Veri) Modeli Deneysel Sonuçları | 80 |
| 4.2.7. U-Net + MobileNet (Veri Artırmasız) Modeli Deneysel Sonuçları | 83 |
| 4.2.8. U-Net + MobileNet (Artırılmış Veri) Modeli Deneysel Sonuçları | 86 |
| 4.2.9. U-Net + EfficientNetB3 (Veri Artırmasız) Modeli Deneysel Sonuçları .. | 89 |
| 4.2.10. U-Net + EfficientNetB3 (Artırılmış Veri) Modeli Deneysel Sonuçları . | 92 |
| 4.3. Transfer Öğrenme Modelleri ile U-Net Tabanlı Transfer Öğrenme Modellerinin Karşılaştırılması | 95 |

SONUÇLAR VE ÖNERİLER

| | |
|-----------------------|------------|
| KAYNAKÇA | 106 |
| ÖZGEÇMİŞ..... | 112 |



TABLolar LİSTESİ

| | |
|--|----|
| Tablo 3.1: 7023 MR görüntüsü içeren veri seti örnek sayısı (Veri Seti 1) | 21 |
| Tablo 3.2: 3264 MR görüntüsü içeren veri seti örnek sayısı (Veri Seti 2) | 21 |
| Tablo 3.3: 10287 MR görüntüsü içeren birleştirilmiş veri seti örnek sayısı (Veri Seti 1+ Veri Seti 2)..... | 22 |
| Tablo 3.4: Cohen'in f^2 Değerleri ve Açıklamaları | 24 |
| Tablo 4.1: ResNet50 Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri.. | 49 |
| Tablo 4.2: InceptionNetV3 Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri..... | 53 |
| Tablo 4.3: VGG19 Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri | 56 |
| Tablo 4.4: MobileNet Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri | 58 |
| Tablo 4.5: EfficientNetB3 Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri | 61 |
| Tablo 4.6: U-Net + ResNet50 (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri | 65 |
| Tablo 4.7: U-Net + ResNet50 (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri | 69 |
| Tablo 4.8: U-Net + InceptionNetV3 (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri..... | 72 |
| Tablo 4.9: U-Net + InceptionNetV3 (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri..... | 75 |
| Tablo 4.10: U-Net+VGG19 (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri | 78 |
| Tablo 4.11: U-Net+VGG19 (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri | 81 |

| | |
|---|-----|
| Tablo 4.12: U-Net + MobileNet (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri | 84 |
| Tablo 4.13: U-Net + MobileNet (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri | 87 |
| Tablo 4.14: U-Net + EfficientNetB3 (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri..... | 90 |
| Tablo 4.15: U-Net + EfficientNetB3 (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri..... | 93 |
| Tablo 4.16: ResNet50 ve U-Net Tabanlı ResNet50 Modellerine ait Doğruluk Değerleri Karşılaştırması..... | 96 |
| Tablo 4.17: InceptionNetV3 ve U-Net Tabanlı InceptionNetV3 Modellerinin Doğruluk Değerleri Karşılaştırması | 97 |
| Tablo 4.18: VGG19 ve U-Net Tabanlı VGG19 Modellerinin Doğruluk Değerleri Karşılaştırması..... | 98 |
| Tablo 4.19: MobileNet ve U-Net Tabanlı MobileNet Modellerinin Doğruluk Değerleri Karşılaştırması..... | 99 |
| Tablo 4.20: EfficientNetB3 ve U-Net Tabanlı EfficientNetB3 Modellerinin Doğruluk Değerleri Karşılaştırması | 100 |

ŞEKİLLER LİSTESİ

| | |
|--|----|
| Şekil 3.1: Glioma Tümör, Meningioma Tümör, Pituitary Tümör ve Tümörsüz beyin MR Görüntü Örnekleri | 22 |
| Şekil 3.2: Veri Setindeki Her Sınıfa ait Artırılmış MR Görüntüsü Örnekleri | 28 |
| Şekil 3.3: Örnek Sözde (Pseudo) Mask Görüntüleri..... | 32 |
| Şekil 3.4: Şekil 4. U-Net Mimarisi | 34 |
| Şekil 3.5: U-Net Tabanlı Ön Eğitimli Derin Öğrenme Modellerine Ait Çok Modlu Veri Füzyonu Akış Diyagramı | 35 |
| Şekil 3.6: U-Net Segmentasyon İşlemi Sonucu Tahmini Maskelenmiş Görsel Örnekleri | 37 |
| Şekil 3.7: Artık Blok Örneği..... | 39 |
| Şekil 3.8: (a) Inception Modülü (ilk sürüm). (b) Boyutluluğu azaltmak için tasarlanmış Inception modülü. | 41 |
| Şekil 3.9: VGG19 Modeli Mimarisi..... | 42 |
| Şekil 3.10. MobileNet Modeli Mimarisi..... | 44 |
| Şekil 3.11: EfficientNet Modeli Ölçeklendirmesi. (a) bir temel ağ örneği (b)-(d) ağın sadece bir boyutunu artıran geleneksel ölçeklendirme (genişlik, derinlik veya çözünürlük olarak) (e) her üç boyutu da sabit bir oranla eşit şekilde ölçeklendiren önerilen bileşik ölçeklendirme yöntemi | 46 |
| Şekil 4.1: ResNet50 Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Validasyon Doğruluğu Grafiği ve (b) Eğitim/Validasyon Kaybı Grafikleri..... | 49 |
| Şekil 4.2: ResNet50 Modeline ait Sınıflandırma Raporu | 50 |
| Şekil 4.3: ResNet50 Modeline ait Karmaşıklık Matrisi (Confusion Matrix)..... | 50 |
| Şekil 4.4: ResNet50 Modeline ait Beyin Tümörü Tahmin Görselleştirmesi | 51 |

| | |
|---|----|
| Şekil 4.5: InceptionNetV3 Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 52 |
| Şekil 4.6: InceptionNetV3 Modeline ait Sınıflandırma Raporu | 53 |
| Şekil 4.7: InceptionNetV3 Modeline ait Karmaşıklık Matrisi (Confusion Matrix)... | 53 |
| Şekil 4.8: InceptionNetV3 Modeline ait Beyin Tümörü Tahmin Görselleştirmesi ... | 54 |
| Şekil 4.9: VGG19 Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 55 |
| Şekil 4.10: VGG19 Modeline ait Sınıflandırma Raporu..... | 56 |
| Şekil 4.11: VGG19 Modeline ait Karmaşıklık Matrisi (Confusion Matrix)..... | 56 |
| Şekil 4.12: VGG19 Modeline ait Beyin Tümörü Tahmin Görselleştirmesi | 57 |
| Şekil 4.13: MobileNet Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 58 |
| Şekil 4.14: MobileNet Modeline ait Sınıflandırma Raporu | 59 |
| Şekil 4.15: MobileNet Modeline ait Karmaşıklık Matrisi (Confusion Matrix) | 59 |
| Şekil 4.16: MobileNet Modeline ait Beyin Tümörü Tahmin Görselleştirmesi..... | 60 |
| Şekil 4.17: EfficientNetB3 Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 61 |
| Şekil 4.18: EfficientNetB3 Modeline ait Sınıflandırma Raporu | 62 |
| Şekil 4.19: EfficientNetB3 Modeline ait Karmaşıklık Matrisi (Confusion Matrix) .. | 62 |
| Şekil 4.20: EfficientNetB3 Modeline ait Beyin Tümörü Tahmin Görselleştirmesi... 63 | |
| Şekil 4.21: U-Net + ResNet50 (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 64 |
| Şekil 4.22: U-Net + ResNet50 (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu | 65 |

| | |
|---|----|
| Şekil 4.23: U-Net + ResNet50 (Veri Artırmasız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)..... | 66 |
| Şekil 4.24: U-Net + ResNet50 (Veri Artırmasız) Modeline ait Beyin Tümörü Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)..... | 66 |
| Şekil 4.25: U-Net + ResNet50 (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 68 |
| Şekil 4.26: U-Net + ResNet50 (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu..... | 69 |
| Şekil 4.27: U-Net + ResNet50 (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)..... | 70 |
| Şekil 4.28: U-Net + ResNet50 (Artırılmış Veri) Modeline ait Beyin Tümörü Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)..... | 70 |
| Şekil 4.29: U-Net + InceptionNetV3 (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 71 |
| Şekil 4.30: U-Net + InceptionNetV3 (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu..... | 72 |
| Şekil 4.31: U-Net + InceptionNetV3 (Veri Artırmasız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)..... | 73 |
| Şekil 4.32: U-Net + InceptionNetV3 (Veri Artırmasız) Modeline ait Beyin Tümör Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)..... | 73 |
| Şekil 4.33: U-Net + InceptionNetV3 (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 75 |
| Şekil 4.34: U-Net + InceptionNetV3 (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu..... | 76 |
| Şekil 4.35: U-Net + InceptionNetV3 (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)..... | 76 |

| | |
|--|----|
| Şekil 4.36: U-Net + InceptionNetV3 (Artırılmış Veri) Modeline ait Beyin Tümörü Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)..... | 77 |
| Şekil 4.37: U-Net + VGG19 (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 78 |
| Şekil 4.38: U-Net + VGG19 (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu..... | 79 |
| Şekil 4.39: U-Net + VGG19 (Veri Artırmasız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)..... | 79 |
| Şekil 4.40: U-Net + VGG19 (Veri Artırmasız) Modeline ait Beyin Tümörü Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)..... | 80 |
| Şekil 4.41: U-Net + VGG19 (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 81 |
| Şekil 4.42: U-Net + VGG19 (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu..... | 82 |
| Şekil 4.43: U-Net + VGG19 (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)..... | 82 |
| Şekil 4.44: U-Net + VGG19 (Artırılmış Veri) Modeline ait Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile) | 83 |
| Şekil 4.45: U-Net + MobileNet (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 84 |
| Şekil 4.46 U-Net + MobileNet (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu..... | 85 |
| Şekil 4.47: U-Net + MobileNet (Veri Artırmasız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)..... | 85 |
| Şekil 4.48: U-Net + MobileNet (Veri Artırmasız) Entegre Modeline ait Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)..... | 86 |

| | |
|---|----|
| Şekil 4.49: U-Net + MobileNet (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 87 |
| Şekil 4.50: U-Net + MobileNet (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu | 88 |
| Şekil 4.51: U-Net + MobileNet (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix) | 88 |
| Şekil 4.52: U-Net + MobileNet (Artırılmış Veri) Modeline ait Tahmin Görselleştirmesi (U-Net Tahmin Maskesi ile) | 89 |
| Şekil 4.53: U-Net + EfficientNetB3 (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 90 |
| Şekil 4.54: U-Net + EfficientNetB3 (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu | 91 |
| Şekil 4.55: U-Net + EfficientNetB3 (Veri Artırmasız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix) | 91 |
| Şekil 4.56: U-Net + EfficientNetB3 (Veri Artırmasız) Entegre Modeline ait Eğitim/Doğrulama Doğruluğu ve Eğitim/Doğrulama Kaybı Grafikleri | 92 |
| Şekil 4.57: U-Net + EfficientNetB3 (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri | 93 |
| Şekil 4.58: U-Net + EfficientNetB3 (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu | 94 |
| Şekil 4.59: U-Net + EfficientNetB3 (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix) | 94 |
| Şekil 4.60: U-Net+EfficientNetB3 (Artırılmış Veri) Modeline ait Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile) | 95 |
| Şekil 4.61: ResNet50 ve U-Net Tabanlı ResNet50 Modellerinin Doğruluk Grafikleri (a) ResNet50 Modeli (b) Veri Artırmasız U-Net + ResNet50 Modeli (c) Artırılmış Veri ile U-Net + ResNet50 Modeli | 96 |

Şekil 4.62: InceptionNetV3 ve U-Net Tabanlı InceptionNetV3 Modellerinin Doğruluk Grafikleri (a) InceptionNetV3 Modeli (b) Veri Artırmasız U-Net + InceptionNetV3 Modeli (c) Artırılmış Veri ile U-Net + InceptionNetV3 Modeli 97

Şekil 4.63: VGG19 ve U-Net Tabanlı VGG19 Modellerinin Doğruluk Grafikleri (a) VGG19 Modeli (b) Veri Artırmasız U-Net + VGG19 Modeli (c) Artırılmış Veri ile U-Net + VGG19 Modeli 98

Şekil 4.64: MobileNet ve U-Net Tabanlı MobileNet Modellerinin Doğruluk Grafikleri (a) MobileNet Modeli (b) Veri Artırmasız U-Net + MobileNet Modeli (c) Artırılmış Veri ile U-Net + MobileNet Modeli 99

Şekil 4.65: EfficientNetB3 ve U-Net Tabanlı EfficientNetB3 Modellerinin Doğruluk Grafikleri (a) EfficientNetB3 Modeli (b) Veri Artırmasız U-Net + EfficientNetB3 Modeli (c) Artırılmış Veri ile U-Net + EfficientNetB3 Modeli..... 100

KISALTMALAR LİSTESİ

MR: Manyetik Rezonans

MRG: Manyetik Rezonans Görüntüleme

CNN: Convolutional Neural Network (Evrışimsel Sinir Ağı)

CNS: Central Nervous System (Merkezi Sinir Sistemi)

SVM: Support Vector Machine (Destek Vektör Makinesi)

KNN: K-Nearest Neighbour (K-En Yakın Komşu)

ResNet50: Residual Network

VGG19: Visual Geometry Group 19

MobileNet: Mobile Networks

WHO: World Health Organization (Dünya Sağlık Örgütü)

BİRİNCİ BÖLÜM

GİRİŞ

Yapay zeka, insan zekası süreçlerinin makineler ve özellikle bilgisayar sistemleri tarafından simülasyon olarak işlenmesine denir ve yapay zekanın özel uygulamaları arasında uzman sistemler, doğal dil işleme, konuşma tanıma ve makine görmesi gibi alanlar bulunmaktadır. Yapay zeka uygulamalarının bir sınırı olmamakla birlikte yapay zeka teknolojisi birçok farklı sektör ve endüstriye uygulanabilmektedir. Sağlık alanında da gün geçtikçe önemli bir rol oynayan yapay zeka, bu sektörde hastalıkların tahmini, sınıflandırılması, hastalar için farklı tedavi yöntemlerinin belirlenmesi gibi işlemler için kullanılabilir. Özellikle insanlar tarafından yapılan görevleri daha kısa sürede ve maliyetin çok altında gerçekleştiren yapay zeka; hastaların, doktorların ve hastane yöneticilerinin hayatlarını kolaylaştıran önemli bir atılım olmuştur.

Sağlık hizmetlerinde verilerin karmaşıklığı ve yükselişi, yapay zekanın (AI) sahada giderek daha fazla uygulanacağı anlamına gelmektedir. Halihazırda, yapay zekanın hastalıkların teşhisi gibi temel sağlık hizmetlerinde insanlar kadar veya onlardan daha iyi performans gösterebileceğini öne süren bir dizi araştırma çalışması bulunmaktadır. (Davenport ve Kalakota, 2019).

Dünya Sağlık Örgütü (WHO) verilerine göre, habis tümör veya ur olarak da adlandırılan kanser hastalığı, dünya genelinde ikinci en sık ölüm nedeni olarak karşımıza çıkmaktadır. Dünya genelinde 2022'de, 20 milyon 27bin 686 kişiye kanser teşhisi konulurken, 9 milyon 738 bin 835 kişi kanser nedeniyle hayatını kaybetmiştir. Tüm tümör çeşitleri içinde beyin tümörü yaygınlığı ise, evrensel ölüm oranında önemli payı olan bir ölüm nedenidir. GLOBOCAN 2022 raporuna göre beyin kanseri vaka sayısı 321.624 olmuş ve insanların %2,55'i beyin kanserinden hayatlarını kaybetmişlerdir (Kim, vd., 2025). Ancak kanser taraması, tedavisi ve önlenmesindeki gelişmeler sayesinde birçok kanser türü için hayatta kalma oranları artmaktadır ve yapay zeka uygulamaları da kanserin taraması, tedavisi ve önlenmesinde kritik bir rol oynamaktadır.

Günümüzde çok sayıda insan için çok önemli bir ölüm faktörü haline gelen tümör çeşitleri arasında beyin tümörü ciddiyeti çok yüksek olan bir tümör çeşidi olup beyin tümörü varlığı durumunda hayat kurtarmak için anında tespit ve uygun bakım yapılması oldukça önem arz etmektedir. Radyologların teşhis etmekte zorlanabilme

durumları ve ölümcül olan beyin tümörlerinin özellikle kötü huylu (malign) kanserlerin doğru ve zamanında sınıflandırılmasına dayalı olarak tedaviyle ilgili kararların alınması kritik öneme sahiptir. Özellikle çok sayıda Manyetik Rezonans Görüntüsünü (MRG) kontrol edilmesi ve bir insan tarafından manuel olarak bir beyin tümörünün tespit edilmesi hataya açık olabilecek, zaman alıcı ve sürdürülebilirliği düşük bir iş olarak görülmektedir. Ayrıca bu metot hastanın uygun tedavisini de etkileyebilmektedir. Normal doku ve beyin tümörü hücreleri arasında görünüşte oldukça benzerlikler vardır, bu nedenle tümör bölgelerinin bölütlenmesi zor bir iş haline gelmektedir. Bu nedenle, oldukça hassas bir otomatik tümör tespit yöntemi bir zorunluluk haline gelmiştir. Bu amaçla son yıllarda beyin tümörlerini saptamak için çeşitli yaklaşımlar sunulmuştur. Özellikle bu yaklaşımlar içerisinde derin öğrenme modellerinden olan ön eğitilmiş derin öğrenme modelleri dikkat çekmektedir.

Son yıllarda, beyin tümürlü hastaları iyileştirmek amacıyla yapay zeka oldukça geliştirilmiş olup literatürde beyin tümörünün moleküler sınıflandırması, farklılaşması ve tedavi yanıtı ile ilgili olarak nöro-onkolojide makine öğrenimi tabanlı ve derin öğrenme tabanlı yapay zeka kullanımı çok fazla araştırmanın konusu olmuştur.

Ön eğitilmiş derin öğrenme modellerinin kullanılmasının en önemli avantajı yeni problemler için modeller oluştururken gereken hesaplama maliyetlerini azaltmasıdır. Önceden eğitilmiş modelleri veya önceden eğitilmiş ağırları farklı bir görevi ele almak için yeniden kullanarak kullanıcılar model eğitim süresi, eğitim verileri, işlemci birimleri ve diğer hesaplama kaynaklarının miktarını azaltabilmektedirler. Bu bağlamda önceden eğitilmiş bir model kullanarak yeni bir modeli eğitmek için gereken süre önemli ölçüde azaltılabilmekte, öğrenilen özellikleri yeniden kullandığı için daha az hesaplama kaynağı ihtiyacıyla sıfırdan kapsamlı eğitim ihtiyacı en aza indirilebilmekte ve özellikle yeni görev için mevcut verilerin sınırlı olduğu durumlarda, genellikle daha iyi performans göstermektedir. Önceden eğitilmiş model, yeni görevin belirli gereksinimlerine göre ince ayarlanabilen yararlı özellikleri zaten öğrenmiş olup farklı alanlar ve görevler arasında bilgiyi genelleştirmede ümit verici sonuçlar göstermiştir. Özellikle bilgisayarlı görme ve doğal dil işleme gibi alanlarında önceden eğitilmiş modellerin giderek daha fazla kullanılması araştırmacılar için de bir çalışma perspektifi oluşturmuştur.

Transfer öğrenme modelleri, tıbbi görüntü analiz görevlerinin performansını iyileştirmek için önceden eğitilmiş CNN modellerinden yararlanmanın etkili bir teknik

olduğu saptanmış olup CNN'ler, tıbbi görüntülerden çeşitli tıbbi durumları belirleme ve sınıflandırmada yüksek doğruluk ve sağlamlık göstermiştir (Salehi, vd., 2023).

Bu tez çalışması, manyetik rezonans (MR) görüntüleri aracılığıyla beyin tümörlerinin sınıflandırılmasına odaklanmaktadır. Araştırma kapsamında, yalnızca tümör bölgelerini içeren maskelenmiş MR görüntüleri kullanılarak, dört farklı kategoriye (glioma, meningioma, hipofiz tümörü ve tümörsüz) ait beyin durumlarının ayrıştırılması hedeflenmektedir. Maskeleyiş işlemiyle, görüntüde tümöre ait alanlar öne çıkarılmış; böylece sınıflandırma algoritmalarının sadece anlamlı bilgilere odaklanarak daha yüksek doğruluk oranlarına ulaşması amaçlanmıştır.

Sınıflandırma sürecinde, önceden büyük veri kümelerinde eğitilmiş ve transfer öğrenme temelli mimarilerden oluşan çeşitli derin öğrenme modelleri (ResNet50, InceptionNetV3, VGG19, MobileNet ve EfficientNetB3) kullanılmıştır. Bu modellerin başarımı, doğruluk (accuracy), hassasiyet (precision), özgüllük (specificity) ve F1 skoru gibi istatistiksel performans ölçütleri ile değerlendirilmiştir. Ayrıca, görüntü ön işleme adımlarına maskeleyiş uygulamalarının yanı sıra veri artırma (data augmentation) yöntemleri de entegre edilerek, bu işlemlerin model başarısı üzerindeki etkileri detaylı şekilde analiz edilmiştir.

Bu tez çalışmasının yalnızca görüntü verilerine dayalı bir sınıflandırma süreci içerdiği belirtilmelidir. Yaş, cinsiyet, semptomatik özellikler gibi klinik veriler ile genetik ya da biyokimyasal göstergeler araştırma kapsamının dışında tutulmuştur. Elde edilen çıktıların doğrudan klinik tanı koyma amacı taşımadığı, bunun yerine hekimlere destek sağlayacak bir karar destek altyapısı oluşturmayı hedeflediği dikkate alınmalıdır. Bu bağlamda tez çalışması, görüntü işleme teknikleri ve ön eğitilmiş derin öğrenme disiplinlerini bütüncül bir yaklaşımla birleştiren, çok alanlı bir araştırma niteliği taşımaktadır.

Tez çalışmasının konusunu iki aşamada özetlemek gerekirse; beyin tümör tespiti ve sınıflandırılması amacıyla açık erişime sahip olan aynı formatlı beyin MR görüntü veri setlerini birleştirerek daha büyük bir veri seti elde ettikten sonra bu yeni veri seti üzerinde veri artırma işlemi uygulanarak veri çeşitliliğinin artırılması ve radyomik tabanlı önceden eğitilmiş derin öğrenme modelleriyle U-Net tabanlı maskeleyiş işlemi ile entegre edilmiş hibrit modellerin incelenmesidir. Ön eğitilmiş modellerin

performansları hem ayrı hem de U-Net tabanlı maskeleye işlemi ile entegre edilmiş hibrit model şeklinde değerlendirilecektir.

1.1. Problem

Manyetik Rezonans Görüntüleme (MRG), beyin dokularının yüksek çözünürlükle görüntülenmesini sağlayan ve nörolojik hastalıkların görüntülenmesinde sıklıkla başvurulan önemli bir tekniktir. Diğer yandan, elde edilen MR görüntüleri yalnızca hedef bölge olan tümörü değil, aynı zamanda beyin dışı yapılar, arka plan bilgileri ve çeşitli görüntü gürültülerini de içermektedir. Bu tür ilgisiz görüntü içerikleri, derin öğrenme ve makine öğrenmesi algoritmaları kullanıldığında, modelin dikkatini tümörden uzaklaştırarak sınıflandırma başarımını olumsuz yönde etkileyebilmektedir.

Son dönem çalışmalarında, transfer öğrenmeye dayalı derin öğrenme yaklaşımlarının tıbbi görüntü sınıflandırmasında umut vadeden sonuçlar sunduğu görülmektedir. Ancak bu başarı, büyük ölçüde kullanılan görüntülerin kalitesine ve ön işleme sürecinin etkinliğine bağlıdır. Literatürde yer alan bazı çalışmalarda, MR görüntüleri üzerinde ön işleme teknikleri uygulamadan sınıflandırma modellerine doğrudan aktarılmakta; bu da tümör dışı bölgelerin modele dahil edilmesine ve dolayısıyla sınıflandırma doğruluğunun düşmesine yol açmaktadır. Böyle bir durum, modelin öğrenme sürecini zorlaştırmakta ve nihai kararların güvenilirliğini azaltmaktadır.

Bu çalışma, söz konusu zorlukları gidermek amacıyla, MR görüntülerinin öncelikle maskeleye teknikleriyle işlenerek tümör bölgesinin öne çıkarılmasını önermektedir. Bu şekilde elde edilen filtrelenmiş görüntüler üzerinden transfer öğrenme yöntemleri kullanılarak daha güvenilir ve isabetli sınıflandırma sonuçları elde edilmesi hedeflenmektedir. Araştırmanın temel amacı, hem tanı sürecini kısmen otomatikleştirerek sağlık hizmetlerine hız kazandırmak hem de sınıflandırma modellerinin doğruluğunu artırmaktır. Bu yönüyle çalışma, tıbbi görüntü analizi literatüründe önemli bir boşluğu doldurmayı hedeflemekte ve klinik karar destek sistemlerinin geliştirilmesine somut katkılar sunmayı amaçlamaktadır.

1.2. Amaç

Bu araştırmanın temel amacı, ön işleme sürecinden geçirilmiş (maskelenmiş) MR görüntülerinin kullanılmasıyla beyin tümörlerini doğru ve efektif bir şekilde sınıflandırabilecek bir yöntem geliştirmektir. Bu doğrultuda, tıbbi görüntü işleme metotlarıyla birlikte derin öğrenme yaklaşımlarının bir araya getirilmesiyle, beyin tümörlerinin otomatik olarak sınıflandırılması için bir karar sisteminin tasarlanması amaçlanmaktadır.

Son yıllarda, sınırlı sayıda verinin bulunduğu özellikle tıbbi görüntüleme alanlarında, transfer öğrenme temelli derin öğrenme modelleri büyük avantajlar sağlamaktadır. Bu tez çalışması kapsamında, daha önce büyük veri setleri üzerinde eğitimi tamamlanmış ve yüksek genelleme kapasitesine sahip çeşitli derin öğrenme mimarileri (ResNet, InceptionNetV3, VGG19, MobileNet ve EfficientNetB3) kullanılarak, beyin tümörlerinin dört farklı sınıfta (Glioma, Meningioma, Hipofiz tümörü ve tümör bulunmayan) sınıflandırılması planlanmaktadır. Modelin daha isabetli tahminlerde bulunabilmesi için, yalnızca tümör bölgesini içeren maskelenmiş MR görüntüleri tercih edilecektir. Bu sayede modele yalnızca sınıflandırma açısından anlamlı verilerin sunulması sağlanarak, genel performansın artırılması amaçlanmaktadır.

Bu çalışma, görüntü işleme (maskeleme) ve derin öğrenme (transfer öğrenme) yöntemlerini bir araya getirerek geleneksel yöntemlerin ötesinde bir çözüm geliştirmeyi hedeflemektedir. Ortaya konacak sistem, klinik süreçlerde beyin tümörlerinin tanılanmasına destek olabilecek, kullanışlı, hatasız ve daha hızlı bir yapay zeka ile üretilmiş karar mekanizması niteliğinde olacaktır. Ayrıca bu tez çalışmasında, tıbbi görüntüler üzerinde uygulanan etkili ön işleme adımlarının sınıflandırma doğruluğu üzerine olan etkilerinin de sistemli bir şekilde incelenerek literatüre katkı sunulması amaçlanmaktadır.

1.3. Araştırmanın Önemi

Beyin tümörleri hem tanı hem de tedavi sürecinde ciddi zorluklar barındıran ve bireyin yaşam kalitesini doğrudan etkileyen önemli sağlık problemlerindedir. Özellikle tümörün tipi, yerleşimi ve evresi gibi faktörler, uygulanacak tedavi yönteminin belirlenmesinde belirleyici rol oynamaktadır. Doğru ve erken tanı, hastanın yaşam süresi ve iyileşme olasılığı açısından kritik öneme sahiptir. Bu noktada manyetik

rezonans görüntülemenin (MRG), yumuşak dokuları yüksek çözünürlükle görüntüleyebilmesi bu yöntemi beyin tümörlerinin tespit edilmesinde en sık başvurulan ve etkili görüntüleme yöntemlerinden biri olarak öne çıkarmaktadır. Ancak MR görüntülerinin manuel bir şekilde analiz edilmesi; uzun sürebilecek, yoruma açık ve insan hatasına açık bir süreçtir. Bu durum, özellikle radyolog sayısının yetersiz olduğu veya iş yükünün fazla olduğu sağlık sistemlerinde önemli bir sorun haline gelmektedir.

Son dönemde, derin öğrenme ve özellikle transfer öğrenme yaklaşımları, tıbbi görüntü analizi alanında dikkate değer gelişmelere zemin hazırlamıştır. Daha önce büyük veri setleri üzerinde eğitilmiş modellerin, küçük ölçekli tıbbi veri kümelerinde de yüksek başarıyla sınıflandırma yapabildiği gözlemlenmiştir. Bu tür modeller, eğitim sürecini önemli ölçüde kısaltmakta ve klinik uygulamalarda hızlı, güvenilir ve uygulanabilir karar destek sistemlerinin geliştirilmesine katkı sunmaktadır. Özellikle transfer öğrenme tabanlı yöntemler, uzmanlık gerektiren tanı süreçlerinde kullanılacak önemli bir araç haline gelmiştir.

Ayrıca, MR görüntülerinin daha verimli işlenebilmesi için çeşitli ön işleme tekniklerinin uygulanması da model başarımı açısından oldukça önemli bir işlemdir. Bu tez çalışması kapsamında uygulanan "maskeleye" işlemi, görüntüde yer alan alakasız arka plan unsurlarını ayıklayarak modelin yalnızca tümör bölgesine odaklanmasını sağlamayı hedeflemektedir. Bu sayede, sınıflandırma algoritmalarının genelleme yeteneği artırılarak daha doğru sonuçlar elde edilmesi amaçlanmaktadır.

Bu araştırmanın önemi, görüntü işleme ile derin öğrenme yöntemlerini bir araya getirerek sağlık alanında disiplinler arası bir yaklaşım sunmasından kaynaklanmaktadır. Maskelenmiş MR görüntüleri üzerinde transfer öğrenme teknikleri kullanılarak yapılacak sınıflandırma çalışması, literatüre yenilikçi bir katkı sağlayacak ve klinik karar destek sistemlerinin gelişimine zemin oluşturacaktır. Aynı zamanda, düşük maliyetli, hızlı ve güvenilir tanı sistemlerinin oluşturulması adına yapılan önemli bir başlangıç olarak düşünülebilir. Bu yönüyle çalışma hem akademik dünyaya hem de sağlık hizmetlerine somut faydalar sunma potansiyeli taşımaktadır.

1.4. Sınırlılıklar

Bu tez çalışmasının çeşitli sınırlılıkları olduğu varsayılmaktadır ve söz konusu kısıtların, geliştirilen sistemin klinik ortamlardaki uygulanabilirliği ve geçerliliği üzerinde etkili olabileceği düşünülmektedir.

Kısıtlardan ilki, çalışmada yalnızca görsel verilere (MR görüntüleri) dayalı bir analiz gerçekleştirilmiş olup; hastaya ilişkin demografik bilgiler, klinik bulgular, genetik veriler ya da histopatolojik sonuçlar sınıflandırma sürecine dahil edilmemiştir. Bu bağlamda, modelin çıktılarını çok boyutlu bir tıbbi değerlendirme yerine, yalnızca görüntü temelli bir analizden elde edilen sonuçları yansıtmaktadır.

Bir diğer sınırlılık ise maskeleye sürecine ilişkindir. Maskelenmiş görüntülerin oluşturulmasında kullanılan tekniklerin doğruluğu, sınıflandırma performansını doğrudan etkilemektedir. Özellikle manuel ya da otomatik yöntemlerle oluşturulan maskelerin hatalı veya eksik olması, modelin tümör bölgesine odaklanmasını engelleyebilir ve bu da öğrenme sürecinin verimliliğini azaltabilir.

Son olarak, geliştirilen modelin doğrudan klinik ortamlarda uygulanabilmesi adına bazı ek gereksinimler söz konusudur. Gerçek zamanlı uygulama, kullanıcı dostu arayüzlerin geliştirilmesi, çeşitli hasta profillerinde geniş çaplı testlerin yapılması ve klinik doğrulama (validasyon) süreçlerinin tamamlanması bu bağlamda kritik önemdedir. Bu tez çalışması sonucunda, temel anlamda, bir sınıflandırma prototipi sunulmuş olup, doğrudan bir tanı aracı olarak değerlendirilmemelidir.

İKİNCİ BÖLÜM

LİTERATÜR TARAMASI

Beyin dokusundaki hücreler anormal şekilde büyüdükçe beyinde tümörler oluşur. Beyindeki tümörlerin büyük bir kısmı kanserli olduğu için hasta kişinin ölümüne varan sonuçları olabilir. En yaygın beyin tümörleri, sistemik kanserlerden, meningiomlardan ve gliomlardan, özellikle glioblastomdan intrakraniyal metastazlardır. Merkezi sinir sistemi metastazları, nöroaks boyunca herhangi bir yerde ortaya çıkabilir ve beyin cerrahisi, radyasyon onkolojisi ve tıbbi onkoloji ile karmaşık multidisipliner bakım gerektirir. Meningiomlar, çoğunlukla iyi huylu olan ve sıklıkla cerrahi rezeksiyonla yönetilen, radyasyon tedavisi ve kemoterapi ile yüksek riskli veya dirençli hastalık için ayrılmış meninks tümörleridir. Glioblastoma, standart bakım eşzamanlı kemoradyasyona sınırlı yanıt veren en yaygın ve agresif malign primer beyin tümörüdür (McFaline-Figueroa ve Lee, 2018). Gliomlar tüm beyin tümörlerinin %70'inden fazlasını oluşturur ve bunların içinde glioblastoma en sık görülen ve malign histolojik tiptir (Dünya Sağlık Örgütü [WHO] derece IV) (Ohgaki, 2009). Birincil CNS tümörleri, CNS içindeki hücrelerden kaynaklanan heterojen bir tümör grubunu ifade eder ve iyi huylu veya kötü huylu olabilirler. Malign (kötü huylu) primer beyin tümörleri, tedavi edilmesi en zor kanserler arasında yer almaya devam etmekte ve 5 yıllık genel sağ kalma oranı %35 oranından daha azdır. Erişkinlerde en sık görülen malign primer beyin tümörleri gliomlardır (Lapointe ve Butowski, 2018).

Tıbbi görüntüleme, doğru tanıyı ortaya çıkarmak ve uygun yönetimi uyarlamak için kullanılan çok önemli tekniklerden biridir. Radyomik, görüntüyü oluşturan anatomik ve fonksiyonel verilerden elde edilen nicel bilgilerin altta yatan patofizyolojiyi yansıttığı hipotezine dayanır. Radyomiklerle ilgili ilk çalışmalar ise daha çok onkoloji alanında yapılmıştır (Bozbuğa ve Gülseçen, 2021). Radyomik, hassas tıp alanında kendini kanıtlama potansiyeline sahip gelişmiş bir görüntü analiz tekniğidir. Radyomik özellikler sadece genomik verilerle korele olmakla kalmaz, aynı zamanda hastalarda sağ kalma tahminini iyileştirmek için tüm tümör hacmi boyunca tümör heterojenliği hakkında tamamlayıcı bilgi de sağlayabilirler (Mayerhoefer, vd., 2020).

Yapay Zekanın (AI), son yıllarda artan hesaplama kapasitesi ve tıbbi veri kullanılabilirliği göz önüne alındığında tıbbi görüntülemenin analizini kolaylaştırmıştır. Beyin tümörlerinin görüntülenmesinde yapay zeka için birçok

uygulama önerilmiş olsa da, potansiyel klinik etkileri üzerinde arařtırmalar sürmektedir. Huang vd., 2022 yılındaki alıřmalarında pediatrik beyin tümörü görüntüleme analizinde yapay zekanın rolü üzerine sistematik bir inceleme yapmıřtır. alıřmanın sonucunda 22 alıřmanın dahil edildiđi 298 kayıt tespit edilmiřtir ve en sık alıřılan tümörler beyin sapı gliomu, ependimom, medulloblastom ve pilositik astrositom gibi posterior fossa tümörleri olmuřtur (%68,15). ođunlukla yapılan iř tümör teřhisi olup (%14,64), bunu tümör segmentasyonu (%3,14) ve tümör tespiti (%3,14) takip etmiřtir.

Radyomik, sinyal yođunluklarının ve piksel iliřkilerinin uzaysal dađılımının matematiksel olarak ıkarılması yoluyla, yapay zeka alanındaki analiz yöntemlerini kullanarak dokusal bilgiyi nicelleřtirir. Görüntülemede farklı alanlardan bugüne kadar yayınlanmış eřitli alıřmalar, radyomiklerin klinik karar vermeyi geliřtirme potansiyelini vurgulamaktadır (Van Timmeren, vd., 2020). Hem hesaplama donanımı hem de makine öğrenimi algoritmalarındaki ilerlemelerin bir sonucu olarak bilgisayarlar, görüntülemeden nicel bilgi elde etmede ve bunları sonuçlarla iliřkilendirmede büyük adımlar atmaktalar. Radyomik, "el yapımı ve derin" olmak üzere iki biçimiyle, tıbbi görüntüleri biyolojik bilgi sađlamak ve teřhis, tedavi, karar desteđi ve izleme için radyolojik fenotipik profil oluřturmaya olanak sađlamak için nicel verilere eviren geliřmekte olan bir alandır (Rogers, vd., 2020)).

Radyomik, tıbbi görüntülerden nicel verilerin ıkarılmasına ve analizine izin veren bir süreç olup tıbbi görüntülemede birok potansiyel uygulama ile geliřen bir arařtırma alanıdır. Radyomik iř akıřında; görüntü elde etme, yeniden oluřturma, ön iřleme, segmentasyon, özellik ıkarma ve analizi gibi iřlem adımları uygulanmaktadır. (Scapicchio, vd., 2021)

Radyomikler, karmařık klinik görüntüleme dizilerinden ok sayıda nicel özelliđin ıkarılmasını sađlarlar ve daha sonra bunları, altta yatan genetik mutasyonları ve maligniteyi yansıtan tümörün histolojik özellikleriyle alakalarını bulmak için ıkarılabilen yüksek boyutlu verilere dönüřtürür (derece, ilerleme, terapötik etki ve hatta genel sađkalım verilerine). Geleneksel beyin görüntüleme ile karřılařtırıldıđında (Yi, vd., 2021), radyomik, anlamlı biyolojik özelliklerle bađlantılı nicel bilgiler ve görüntüleme teřhisinin tam otomasyonuna iřık tutan derin öğrenme uygulaması sađlar. Son alıřmalar, radyomiklerin primer tümörü tanımlamada, ayırıcı tanıda, derecelendirmede, mutasyon durumu ve saldırganlıđın deđerlendirilmesinde, tedavi

yanıtının tahmininde ve hipofiz tümörlerinde, gliomalarda ve beyin metastazlarında nüksün belirlenmesinde oldukça önemli olduğunu göstermiştir.

Makine öğrenimi ile birlikte nicel görüntüleme yöntemlerinin geliştirilmesi, daha kişiselleştirilmiş kanser tedavileri için veri bilimi araştırmalarını çeviriye taşıma fırsatını sağlamıştır. Biriken kanıtlar gerçekten de, invaziv olmayan ileri görüntüleme analitiğinin, yani radyomiklerin, tedavi süreci boyunca ve ötesinde birçok zaman noktasında birden fazla üç boyutlu lezyonlar için tümör fenotipinin temel bileşenlerini ortaya çıkarabildiğini göstermiştir (Avanzo, vd., 2020)). Son yıllarda gelişen derin öğrenme mimarileri; görüntü bölümlendirme, yeniden yapılandırma, tanıma ve sınıflandırma için oldukça etkili potansiyellere sahip olduklarını göstermişlerdir. Gelişmiş yorumlanabilirlik ve tahmin dengesi ile makine ve derin öğrenme alanlarındaki gelecek gelişmeler de radyomik çalışmaları ilerletmeye devam edeceği öngörülmektedir. Yapay zeka (AI), özellikle derin öğrenme, son zamanlarda dikkate değer bir ilerleme kaydetmiş olup bu yöntemler, görüntüleme verilerindeki karmaşık kalıpları nicelleştirmede çok etkilidir ve tümörlerin radyografik özelliklerinin nitel yerine nicel değerlendirmelerini sağlayabilirler. "Radyomik" olarak adlandırılan bu süreç, kanserlerin saptanması, karakterizasyonu ve izlenmesini geliştirmek için geniş fırsatlar oluşturmaya devam etmektedir (Weiss, vd., 2021).

Manyetik Rezonans (MR) görüntüleme, beyin tümörlerinin görüntülenmesinde yaygın olarak kullanılmaktadır. MR görüntüleri, görüntünün dokusunu, kontrastını, parlaklığını ve sınır bilgilerini kullanarak hastalıklı ve sağlıklı alanları ayırt edebilir. Bu sayede beyin tümörünün şekli, yeri, büyüklüğü ve alanı bulunarak hastalığın tedavi sürecinin planlaması yapılabilmektedir. Paul Lauterbur ve Peter Mansfield 1974'te bağımsız olarak daha sonra manyetik rezonans görüntüleme (MRG) olarak bilinen tekniği yayınladıktan sonra, bu teknoloji paha biçilmez bir klinik ve araştırma aracı haline gelmiştir (Geva, 2006). Tıbbi araştırmalarda kullanılmak üzere manyetik rezonans görüntülemenin (MRG) geliştirilmesi, özellikle potansiyel olarak tehlikeli iyonlaştırıcı radyasyona maruz kalmanın önlenmesiyle, teşhis alanında büyük bir ilerleme sağlamıştır. Düşen maliyetler ve daha iyi erişilebilirlik ile MRG kullanımı klinik uygulamada her zamankinden daha yaygın hale gelmektedir (Grover, vd., 2015).

MRG taramaları beyne ve omuriliğe bakmak için çok iyi sonuçlar vermekte ve bu bölgelerdeki tümörleri aramanın en iyi yolu olarak kabul edilmektedir. Sağladıkları görüntüler genellikle BT taramalarından alınan görüntülerden daha ayrıntılıdır.

Manyetik Rezonans Görüntüleme (MRG), üç boyutlu ayrıntılı anatomik görüntüler üreten invaziv olmayan bir görüntüleme teknolojisidir (Weishaupt, vd., 2006). Genellikle hastalık tespiti, teşhisi ve tedavi takibi için kullanılır. Canlı dokuları oluşturan suda bulunan protonların dönme ekseninin yönündeki değişikliği uyaran ve algılayan gelişmiş teknolojiye dayanmaktadır. MRG'lar, vücuttaki protonları bu alanla hizalanmaya zorlayan güçlü bir manyetik alan üreten güçlü mıknatıslar kullanır. Daha sonra hastaya bir radyofrekans akımı gönderildiğinde, protonlar uyarılır ve manyetik alanın çekimine karşı zorlanarak dengeden çıkar. Doktorlar, bu manyetik özelliklere dayanarak çeşitli doku türleri arasındaki farkı söyleyebilirler.

Otomatik beyin tümörü sınıflandırma problemlerinin üstesinden gelmek amacıyla manyetik rezonans görüntüleri (MRG) kullanan uzun kısa süreli bellek (LSTM) modeline dayalı yeni bir yaklaşım önerilen çalışmada (Amin, vd., 2020) sınıflandırma işlemi için dört katmanlı derin LSTM modeli kullanılmıştır. Sonuçlar, BRATS veri setlerinin (BRATS 2012–15, 2018) ve SISS-ISLES 2015 veri setinin farklı versiyonlarında doğrulanmıştır. Farklı veri setlerinden elde edilen doğruluk yüzdelerinin %92,2 ile %100 (sentetik veri) arasında değiştiği gözlemlenmiştir. Bu doğrultuda elde edilen sonuçlar, sunulan yöntemin radyologlara beyin tümörünü tam olarak sınıflandırmaları için daha fazla yardım sağladığını doğrulamıştır.

Beyin tümörü, kanserin en korkunç türlerinden biri olarak kabul edilen ve son yıllarda çocuklar ve yetişkinler arasında çok sayıda ölüme neden olan tümör çeşidi olmuştur. Dünya Sağlık Örgütü (DSÖ) standardına göre 700.000 insan beyin tümörü ile yaşamaktadır ve ortalama hayatta kalma oranı %35 olarak hesaplanmıştır. Bu nedenle, beyin tümörlerini MRG taramaları kullanılarak tam olarak derecelendirmek için otomatik tekniklere ihtiyaç duyulmaktadır. Rehman, vd., 2021 yılındaki çalışmalarında mikroskobik beyin tümörü tespiti ve tümör tipi sınıflandırması için derin öğrenme tabanlı yeni bir yöntem önermişlerdir. Yöntemin ilk adımında 3 boyutlu (3D) evrişimli sinir ağı (CNN) mimarisi tasarlanmış ve çıkarılan tümörler, özellik çıkarımı için önceden eğitilmiş bir CNN modeline geçirilmiştir. Bu seçilen özellikler, son olarak sınıflandırma adımı için ileri beslemeli sinir ağı (feed-forward neural network) aracılığıyla doğrulanmıştır. Çalışmada, doğrulama için üç BraTS veri seti 2015, 2017 ve 2018 kullanılmış ve sırasıyla %98,32, %96,97 ve %92,67 doğruluk elde edilmiştir.

Teknolojinin ve makine öğreniminin gelişmesi, radyologların invaziv önlemler olmadan tümör teşhisinde yardımcı olmaya başlamışlardır. Görüntü segmentasyonu ve sınıflandırmasında önemli sonuçlar elde eden bir makine öğrenimi algoritması, evrişimli sinir ağıdır (CNN). Badža ve Barjaktarović, 2020 yılındaki çalışmalarında üç tümör tipinin beyin tümörü sınıflandırması için yeni bir CNN mimarisi önermişlerdir. Kullanılan veri seti halka açık bir veri seti olup 2017 yılında Cheng tarafından geliştirilmiştir. Veri seti, 233 hastadan toplanan 3064 beyin MRG diliminden oluşmaktadır. Üç çeşit beyin tümörü içerir: meningioma, hipofiz ve glioma. Modelin doğruluğu %96,56 olarak hesaplanmıştır. Beyin tümörünün doğru teşhisi, beyin tümörü hastalığı olan hastaların iyileştirilmesi ve varlığının iyileştirilmesi için uygun bir tedavi planlamasının yapılmasında kilit nokta olmuştur. Bilgisayar destekli tümör tespit sistemleri ve evrişimli sinir ağları, başarı öyküleri sağlamakta ve makine öğrenimi alanında önemli adımlar atmaya yol açmaktadır. Derin evrişimli katmanlar, geleneksel önceki sinir ağı katmanlarına kıyasla, giriş alanından otomatik olarak önemli ve sağlam özellikler çıkarırlar. Önceki çalışmada test edilen veri setinin kullanıldığı bu çalışmada (Rehman, vd., 2020) meningiom, glioma ve hipofiz gibi beyin tümörlerini sınıflandırmak için üç evrişimsel sinir ağı mimarisini (AlexNet, GoogLeNet ve VGGNet) kullanan üç çalışma yürütmüştür. Önerilen çalışmalarda, ince ayarlanmış VGG16 mimarisi, sınıflandırma ve algılama açısından 98.69'a kadar en yüksek doğruluğa ulaşmıştır.

Beyin tümörleri tedavisi zor ve dünya çapında önemli ölçüde ölümlere neden olan hastalıklardır. Tıp uzmanları beyin tümörlerini belirlemek için görüntüleri görsel olarak analiz eder ve tümör bölgelerini işaretler fakat bu uygulama zaman alıcı ve hataya açık olan bir uygulamadır. Araştırmacılar son yıllarda , beyin tümörlerini erken tespit etmek için otomatik yöntemler önermişlerdir. Ancak bu yaklaşımlar, düşük doğrulukları ve büyük yanlış pozitif değerleri nedeniyle zorluklarla karşılaşmaktadır. Sağlam özellikleri çıkarmak ve doğru hastalık sınıflandırması gerçekleştirmek için verimli bir tümör tanımlama ve sınıflandırma yaklaşımı gereklidir. Kibriya, vd., 2022 yılındaki makalelerinde derin öznitelik füzyonuna dayalı yeni birçok sınıflı beyin tümörü sınıflandırma yöntemi önermişlerdir. MR görüntüleri min-maks normalleştirme kullanılarak önceden işlenir ve ardından veri eksikliği sorununun üstesinden gelmek için MR görüntülerine kapsamlı veri büyütme uygulanır. AlexNet, GoogLeNet ve ResNet18 gibi transfer öğrenilmiş mimarilerden elde edilen derin CNN

özellikleri, tek bir özellik vektörü oluşturmak için birleştirilir ve ardından nihai çıktıyı tahmin etmek için Destek Vektör Makinesine (SVM) ve K-en yakın komşuya (KNN) yüklenir. Yeni özellik vektörü, bağımsız vektörlerden daha fazla bilgi içerir ve önerilen yöntemin sınıflandırma performansını artırmıştır. Önerilen çerçeve 15320 Manyetik Rezonans Görüntüsü (MRG) üzerinde eğitilip değerlendirilmiştir. Çalışma, birleştirilmiş öznitelik vektörünün tek tek vektörlerden daha iyi performans gösterdiğini göstermiş olup önerilen teknik mevcut sistemlerden daha iyi performans göstererek %99.7 doğruluk elde etmiştir. Bu sonuçlara göre bu modelin klinikler beyin tümörlerini MRG'lerinden sınıflandırmak için kullanılabilmesi sonucuna varılmıştır.

Beyin tümörünün tedavisinde genellikle cerrahi yöntemler tercih edilmektedir. Son zamanlarda biyomedikal alanda hastalıkların tanı ve tedavisinde kullanılan derin öğrenme modelleri yoğun ilgi görmektedir. Toğaçar, vd., 2020 yılındaki çalışmalarında BrainMRNet adlı yeni bir evrişimli sinir ağı modeli önermişlerdir. Önerilen model her katmandan çıkarılan özniteliklerin son katmandaki dizi yapısı tarafından tutulması mantığı ile çalışmaktadır. Amaç, dizide tutulan özellikler arasından en iyi ve en verimli özelliklerin seçilmesidir. BrainMRNet modeli ile beyin tümörünü tespit etmek için erişilebilir manyetik rezonans görüntüleri kullanılmış ve BrainMRNet modelinin, bu çalışmada kullanılan önceden eğitilmiş evrişimli sinir ağı modellerinden (AlexNet, GoogleNet, VGG-16) daha başarılı olduğu gözlemlenmiştir. BrainMRNet modeli ile elde edilen sınıflandırma başarıları %96,05 olmuştur.

Beyin tümörleri hızlı ve agresif bir şekilde gelişerek beyin hasarına neden olabilmekte ve yaşamı tehdit edebilecek düzeye gelebilmektedir. Manyetik rezonans görüntüleme (MRG), bu beyin tümörlerini değerlendirmek için yaygın olarak kullanılan bir görüntüleme tekniğidir, ancak MRG tarafından üretilen büyük miktarda veri nedeniyle manuel segmentasyon yapılması çok uzun bir iştir ve performans büyük ölçüde operatörün deneyimine bağlıdır. Bu bağlamda, tümörün boyutunun etkin bir şekilde ölçülmesi için beyin tümörünü segmentlere ayırmaya yönelik güvenilir bir otomatik segmentasyon yöntemi gereklidir. Cherguif, vd., 2019 yılındaki çalışmalarında U-Net modeline dayalı derin evrişim ağlarını kullanan Derin Öğrenmeye dayalı bir yöntem önermişlerdir. Önerilen metot hem HGG hem de LGG hastalarını içeren Medical Image Computing ve Computer-Assisted Interventions BRATS 2017 veri setleri tarafından sağlanan gerçek görüntüler üzerinde değerlendirilmiştir ve maksimum

0,81805 ve 0,8103 Zar Benzerlik Katsayısı metriği (Dice Similarity Coefficient) elde etmişlerdir.

En sık görülen kötü huylu tümör çeşitlerinden olan gliomaların segmentasyonu ve derecelendirilmesi tanı ve tedavi planlaması için yaygın ve gerekli bir işlemdir. Naser ve Deen, 2020 yılındaki çalışmalarında bu klinik ihtiyacı gidermek amacıyla, tümör segmentasyonu için U-Net tabanlı CNN, önceden eğitilmiş transfer öğrenimi tabanlı VGG16 ve tümör derecelendirmesi için tamamen bağlantılı bir sınıflandırıcıyı birleştiren bir derin öğrenme yaklaşımı geliştirmişlerdir. Segmentasyon ve derecelendirme modelleri, eğitim ve değerlendirmeler için 110 düşük dereceli glioma (LGG) hastasının T1-kontrast öncesi, sıvıyla zayıflatılmış inversiyon geri kazanımı (FLAIR) ve T1-kontrast sonrası MRG görüntülerini kullanılmıştır. Segmentasyon modeliyle elde edilen ortalama zar benzerlik katsayısı (DSC) ve tümör saptama doğruluğu sırasıyla 0.84 ve 0.92 olmuştur.

Önerilen bir diğer çalışmada (Ahuja, vd., 2020), transfer öğrenme tabanlı bir beyin tümörü tespiti sunulmuş ve süperpiksel tekniği kullanılarak bölütleme işlemi yapılmıştır. İlk aşamada, beyin görüntüleri tümörün mevcudiyetine göre normal, Düşük Dereceli Glioma (LGG) ve Yüksek Dereceli Glioma (HGG) olmak üzere üç kategoriye ayrılmış, ikinci aşamada ise süperpiksel segmentasyon tekniği kullanılarak incelenen tümör LGG ve HGG görüntüleri içinde segmentlere ayrılmıştır. Önerilen metodoloji Brain Tumor Segmentation (BraTS) 2019 challenge veri tabanında incelenmiştir. Tümör tespit görevi, VGG-19 transfer öğrenme modelinde gerçekleştirilmiştir ve %99,82 eğitim doğruluğu, %96,32 doğrulama doğruluğu ve %99,30 test doğruluğu elde edilmiştir.

Beyin tümörü sınıflandırma işlemi için geliştirilen bir diğer çalışmada (Yılmaz, 2021), çok kanallı Faster R-CNN tabanlı model uygulanarak üç farklı açık erişim olan beyin MR veri seti ile sınıflandırılmıştır. Popüler derin öğrenme mimarileri olan VGG-16, daha hızlı bölge tabanlı evrişimli sinir ağı (Faster R-CNN), DenseNet-201, Resnet-50 ve SRN modelleri aynı probleme uygulanarak sonuçların karşılaştırılması ve verimliliğin gösterilmesi sağlanmıştır. Önerilen çalışmada modellerin performansını ve verimliliğini göstermek için uygulanan yöntemlerin doğruluğu, duyarlılığı ve işlem süreleri ölçülmüş olup sonuç olarak, önerilen model kullanılarak üç veri seti için en yüksek doğruluk oranları %98.31, %99.6 ve %99.8 olarak elde edilmiştir.

Son zamanlarda, bilgisayar destekli teşhise dayalı sistemler, yardımcı bir teknoloji olarak, manyetik rezonans görüntüleme (MRG) yoluyla beyin tümörünü teşhis etme işlemi için umut vadetmişlerdir. Araştırmacılar çalışmalarında (Noreen, vd., 2020), beyin tümörünün erken teşhisi için çok düzeyli öznelik çıkarma ve birleştirme yöntemi önermişlerdir ve bu amaçla Inception-v3 ve DensNet201 gibi önceden eğitilmiş iki derin öğrenme modeli kullanılmıştır. Önerilen yöntem halka açık üç farklı veri seti üzerinde test edilmiş ve Inception-v3 ve DensNet201 modelleri sırasıyla %99,34 ve %99,51 test doğruluğu üretmiş ve beyin tümörü tespitinde en yüksek performansı elde etmiştir. Sonuçlar doğrultusunda, önceden eğitilmiş modeller kullanılarak özelliklerin birleştirilmesine dayalı önerilen bu yöntem, beyin tümörü sınıflandırması için mevcut son teknoloji derin öğrenme ve makine öğrenimi tabanlı yöntemlere kıyasla daha iyi performans göstermiştir.

Beyin tümörlerinin manuel olarak tanımlanması, radyologlar için hataya açık ve sıkıcı bir işlem olması nedeniyle otomatik bir sistemin benimsenmesi oldukça önemlidir. Multimodal beyin tümörleri sınıflandırması (T1, T2, T1CE ve Flair) radyologlar için zorlu bir işlem olarak kabul edilmektedir. Khan, vd., 2020 yılında yaptıkları araştırmalarında beyin tümörü tipi sınıflandırması için derin öğrenmeyi kullanan otomatikleştirilmiş çok modlu bir sınıflandırma yöntemi sunmuşlardır. Bu yöntemde VGG16 ve VGG19 (önceden eğitilmiş CNN modelleri) ve sınıflandırma işlemi için ELM sınıflandırıcısı kullanılmıştır. Önerilen yöntem BraTS veri setlerinde doğrulanarak BraTs2015, BraTs2017 ve BraTs2018 için sırasıyla %97,8, %96,9 ve %92,5 doğruluk elde edilmiştir.

Beyin tümörü yetişkinlerde ve çocuklarda görülen tehlikeli ve ölümcül kanser türlerinden biridir. Beyin tümörünün erken ve doğru teşhisi tedavi süreci için oldukça önem taşımaktadır. Uzmanların bilgisayar destekli sistemler kullanarak beyin tümörünü tespit etmesi önemli bir adımdır. Bu tespit yönteminin önerildiği bir çalışmada (Çinar ve Yildirim, 2020) MR görüntüleri kullanılarak beyin tümörünün teşhis edilmesi amaçlanmaktadır. Teşhis işlemi için derin öğrenme ağlarından biri olan CNN modellerinden Resnet50 mimarisi kullanılmıştır. Önerilen model Kaggle veri seti ile %97.2 doğruluk değeri elde edilmiş olup ayrıca Alexnet, Resnet50, Densenet201, InceptionV3 ve Googlenet modelleri de test edilmiştir. Sonuç olarak literatürdeki diğer çalışmalar incelendiğinde, geliştirilen bu yöntemin etkili olduğu ve

bilgisayar destekli sistemlerde beyin tümörünün saptanmasında kullanılabileceği sonucuna varılmıştır.

Beyin MRG görüntülerini sınıflandırmak için transfer öğrenme ve önceden eğitilmiş modeller kullanılır ve geleneksel tanı yöntemlerine kıyasla daha hızlı, daha doğru ve tutarlı sonuçlar hedeflenir. Xception, MobileNetV2, InceptionV3, ResNet50, VGG16 ve DenseNet121 gibi önceden eğitilmiş modeller, transfer öğrenmesi yoluyla beyin tümörlerini sınıflandırmak için kullanılır, eğitim süresini ve hesaplama kaynaklarını azaltırken performansı artırır ve kanser teşhisinin iyileştirilmesine katkıda bulunur. Transfer öğrenmesi ve önceden eğitilmiş modeller kullanan derin öğrenme modellerinin performansı, sınıflandırma doğruluğunu ve genel etkinliğini değerlendirmek için dört ayrı sınıfa ayrılmış beyin tümörü MR verileri üzerinde test edilmiş ve önceden eğitilmiş transfer öğrenme modelleri kullanan otomatik beyin tümörü sınıflandırma sistemleri, klinik karar vermeyi destekleyen güvenilir ve ölçeklenebilir modeller sağlamak için önerilmiştir (Disci, vd., 2025). Bu kapsamda araştırdıkları ön eğitilmiş modeller Xception, MobileNetV2, InceptionV3, ResNet50, VGG16, and DenseNet121 modelleridir. Elde ettikleri doğrulama doğruluğu değerleri sırasıyla; %98,73, %98,15, %97,43, %97,41, %96,80 ve %95,83 şeklinde olmuştur.

Derin öğrenme, beyin tümörünün hızlı ve kolay tespiti ve tanımlanması için Manyetik Rezonans Görüntüleme (MRG) görüntüleme kullanılarak beyin tümörü algılama ve sınıflandırma modelleri üretmek için bir teknik olarak kullanılır. Dünya Sağlık Örgütü tarafından Şubat 2018'de yayınlanan yakın tarihli bir raporunda beyin kanserinden veya merkezi sinir sisteminden (CNS) ölüm oranının Asya kıtasında en yüksek olduğunu göstermiştir. Bu hayatların çoğunun kurtarılabilmesi için kanseri erken teşhis etmek önemlidir. Dolayısıyla çalışmanın amacı, doktorun kolay, doğru ve hızlı karar vermesine yardımcı olmak için MRG'ye dayalı beyin tümörünü saptamanın iyi ve etkili bir yolunu bulmaktır. Bu amaçla sinir ağlarına dayalı derin öğrenme algoritmalarının kullanılmış ve beyin tümörü tespiti için 10.000 görüntüden oluşan bir veri kümesini içerecek şekilde uygulanmıştır. Test için Inception, VGG16, MobileNet ve ResNet modelleri kullanmış olup her model için elde edilen f-skor doğruluğu şu şekilde olmuştur: Almadhoun ve Abu-Naser, 2022 yılındaki araştırmalarında geliştirdikleri modelin f-skoru %98.28, VGG16 modelinin f-skoru %99.86, ResNet50 modelinin f-skoru %98.14, MobileNet modelinin f-skoru %88.98 ve InceptionV3 f-skoru %99.88 olmuştur.

Tümörü teşhis etmek için uyarlanmış bilgisayar modellerinde modelin doğruluğunun test edilmesi önemli ve gerekli bir işlemdir. Kumar, K. K., vd., 2023 yılındaki çalışmaları AlexNet, ResNet 50 ve InceptionV3'ten tahmin doğruluğunu dikkate alarak en iyi sınıflandırma sistemini belirlemeyi amaçlayan bir çalışma olup bizim çalışmamıza benzer olarak ResNet50 ve InceptionNetV3 ön eğitilmiş modelleri kullanmışlardır. Artırılmış veriye uyguladıkları AlexNet ile %96,2 doğruluk elde ederek ResNet 50 (93.51%) ve Inception V3'ten (92.07%) daha iyi performans göstermiştir. Diğer bir çalışmada (Shoaib, M. R., vd., 2022) ise dört derin evrişimli sinir ağı ele alınarak karşılaştırılmıştır. Bu ağlar InceptionresnetV2, InceptionV3, transfer öğrenme ve BRAIN-TUMOR-net ağlarıdır. Bu ağlardan artırılmış verilerle elde edilen doğrulama doğruluğu değerleri sırasıyla %94,11, %93,16, %99,99 ve %100 şeklinde olmuştur.

Yapay zeka tabanlı derin öğrenme teknikleri, model yorumlanabilirliğini korurken çeşitli tümör tiplerinde sürekli olarak yüksek doğruluk elde ederek umut verici sonuçlar göstermektedir. Bu gelişmelerden ilham alan bu çalışma (Ishaq, A., vd., 2025), performans ve açıklanabilirlik arasındaki boşluğu ele alarak çok dereceli beyin tümörü tespiti ve sınıflandırması için EfficientNet'in geliştirilmiş bir varyantını sunmuşlardır. %98,6 doğrulama doğruluğu değeri elde eden bu model nöro-onkolojide klinik karar almaya önemli ölçüde yardımcı olma potansiyeline sahip olabilecek bir model niteliği taşımaktadır. CNN, işlenmemiş görüntülerden görsel özellikler çıkararak sınıflandırmayı başarmaktadır ancak eğitim veri kümesinin boyutu CNN'nin çıkardığı özellikler üzerinde önemli bir etkiye sahip olduğundan CNN, veri sayısı küçük olduğunda aşırı uyum sağlama eğiliminde olabilmektedir. Bu amaçla, transfer öğrenmeli derin CNN'ler (DCNN) geliştirilmiştir. Araştırmacılar (Krishnapriya, S., ve Karuna, Y., 2023) çalışmalarında, veri artırma ve transfer öğrenme tekniklerini kullanarak önceden eğitilmiş VGG-16, VGG-19, ResNet50 ve Inception V3 modellerinin beyin MR görüntüleri üzerindeki sınıflandırma potansiyellerini araştırmışlardır. Elde edilen doğrulama doğruluğu değerleri sırasıyla %99,48, %99, %88,87 ve %81,25 şeklindedir.

Hossain vd., 2024 yılındaki çalışmalarında bizim de çalışmamıza benzer nitelikte olarak çeşitli görüntü işleme tekniklerini kullanarak beyin tümörü teşhisinde ön eğitilmiş modelleri kullanmayı amaçlamışlardır. Bu bağlamda inceledikleri ön eğitilmiş modeller; VGG19, MobileNetV2, MobileNetV3, EfficientNet B0, EfficientNet B3,

Inception V3 ve DenseNet201 modelleri olup elde edilen doğrulama doğruluğu değerleri VGG19 için %75, MobileNetV2 için %88, MobileNetV3 için %97, EfficientNet B0 için %99, EfficientNet B3 için %99, Inception V3 için %86 ve DenseNet201 için %90 olarak elde edilmiştir. VGG16, EfficientNet, MobileNet, AlexNet ve ResNet50 dahil olmak üzere birden fazla son teknoloji derin öğrenme (DL) mimarisini bir dikkat mekanizmasıyla entegre ederek beyin MR görüntülerinin sınıflandırılması için yeni bir yaklaşım sunmayı amaçlayan araştırmacılar (Kia, M., vd., 2025) çalışmamızda birleştirdiğimiz veri setinin bir kısmını oluşturan 3264 beyin MR görüntüsünden oluşan veri seti üzerinde çalışmalar yapmışlardır. Bu kapsamda yapan denemelerde her bir model için elde ettikleri en yüksek doğrulama doğruluğu değerleri VGG16 modeli için %70 ResNet50 modeli için %83, MobileNet modeli için %89, AlexNet modeli için %83, EfficientNetB0 modeli için %83, VGG16+ResNet50+AlexNet hibrit model için %84, önerdikleri VGG16+ResNet50+AlexNet+Attention modeli için %85, EfficientNetB0+ResNet50+MobileNet hibrit modeli için %86 ve önerdikleri EfficientNetB0+ResNet50+MobileNet+Attention hibrit modeli için %89 şeklinde elde edilmiştir.

Bu tez çalışmasında ön eğitilmiş modelleri (ResNet50, InceptionNetV3, VGG19, MobileNet, EfficientNetB3) kullanarak sınıflandırma işlemi yapmanın yanı sıra bu sınıflandırma işlemlerini iyileştirmek amacıyla öncelikle U-Net modeli ile beyin MR görüntülerinin segment edilerek özellik çıkarımının yapılması ve bu özelliklerin ön eğitilmiş modellere girdi olarak verilmesi amaçlanmaktadır. Çalışmamızdaki amaca benzer olarak önceki çalışmalarda da her ikisinin de güçlü yönlerinden yararlanarak hem ResNet50 hem de U-Net'in yönlerini birleştiren entegre bir CNN modeli uygulanmıştır. U-Net'in ResNet50 ile entegrasyonu sonucunda (Benchari, M., ve Totaro, M. W., 2024) %0,98, (Saeed, A., vd., 2025) %95 sınıflandırma doğruluğu elde etmişlerdir.

Diğer bir entegre model olan InceptionNetV3 modeli ile U-Net modelinin birleştirildiği model ile çalışan araştırmacıların (Abdelreheem, T. A., vd., 2024) elde ettikleri doğruluk 92.93% olmuştur.

Beyin tümörü segmentasyon görevi, normal dokuya kıyasla anormal bölgelere ait pikselleri belirlemeyi amaçlar. Derin öğrenme, son yıllarda özellikle U-Net benzeri mimariler olmak üzere bu sorunu çözme gücü göstermiştir. Bu makalede (Aboussaleh,

vd., 2023), üç farklı kodlayıcıya sahip verimli bir U-Net mimarisi önerilmiştir: VGG-19, ResNet50 ve MobileNetV2. Yöntem, farklı tümör tiplerini segmentlere ayırmak için BraTS 2020 veri kümesi üzerinde değerlendirilmiş ve sonuçlar, tüm tümör, çekirdek tümör ve kontrast tutan tümör için sırasıyla 0,8741, 0,8069 ve 0,7033 katsayılarıyla zar benzerliği açısından iyi bir performans göstermiştir.

Segmentasyon yoluyla tümörlerin tipi, boyutu ve şekli belirlenebilir ve uygun tedavinin uygulanması mümkün olmaktadır. Araştırmacılar (Eker, vd., 2023) çalışmalarında, yapısal karmaşıklık, görüş açıları, farklı cihaz kullanımları, gürültü ve önyargı alan etkileri açısından farklı görüntüler içeren Beyin Tümörü Figshare (BTF) veri kümesi üzerinde herhangi bir ön işleme uygulanmadan beyin tümörü segmentasyonu yapmayı amaçlamışlardır. U-Net ve FCN gibi temel modeller kullanılmış olup, bu modellerde altta yatan yapı olarak VGG, XceptionNet, InceptionNet ve ResNet mimarileri kullanılarak transfer öğrenme tabanlı yaklaşımlar kullanılmıştır. Deneysel sonuçlara göre, altta yatan yapı olarak VGG-19'a sahip 16 katmanlı FCN mimarisi 0,9169'luk bir zar puanı ile en yüksek puanı elde etmiştir.

MRG beyin tümörü için görüntü segmentasyonu, tümör alanını (ilgi alanı veya ROI olarak) sağlıklı bir beyinden ayırmayı ve tümörün net bir sınırını sağlamayı amaçlar. Araştırmacılar (Pravitasari, vd., 2020) çalışmalarında yeni bir mimari olan UNet-VGG16 tamamen evrişimli ağı kullanarak sınıflandırma yapmışlardır. Bu model veya mimari, U-Net mimarisini basitleştirmek için Transfer Öğrenme ile U-Net ve VGG16'nın birleşimidir. Bu yöntem ile öğrenme veri kümesinde yaklaşık %96,1'lik bir doğruluk elde edilmiştir. Önerilen UNet-VGG16 modeli beyin tümörü alanını ortalama %95,69'luk bir doğru sınıflandırma oranı (CCR) değeriyle tanıyabildiğini göstermiştir.

ÜÇÜNCÜ BÖLÜM

MATERYAL VE YÖNTEMLER

3.1. Veri Seti

Beyin tümörü, beyinde oluşan anormal hücrelerin bir koleksiyonu veya kütesine denir. Beyin tümörleri kanserli (kötü huylu) veya kansersiz (iyi huylu) olabilir. İyi huylu veya kötü huylu tümörler büyüdüklerinde, kafatasının içindeki basıncın artmasına neden olabilirler. Bu durumun sonucunda beyin hasarı oluşabilir ve yaşamı tehdit edebilir seviyeye gelebilmektedir. Beyin tümörü, çocuklar ve yetişkinler arasında agresif hastalıklardan biri olarak kabul edilir. Beyin tümörleri, tüm birincil Merkezi Sinir Sistemi (CNS) tümörlerinin yüzde %85 ile %90'ını oluşturur (Çetin, 2020). Her yıl yaklaşık 11.700 kişiye beyin tümörü teşhisi konulmaktadır. Kanserli beyin tümörü veya merkezi sinir sistemi tümörü olan kişilerde 5 yıllık hayatta kalma oranı erkekler için yaklaşık yüzde 34 ve kadınlar için yüzde 36 olarak hesaplanmıştır. Beyin Tümörleri Benign Tümör, Malign Tümör, Hipofiz Tümörü vb. olarak sınıflandırılır.

Beyin tümörleri karmaşık bir yapıya sahiptir. Beyin tümörünün (tümörlerinin) boyutlarında ve yerlerinde birçok anormallikler bulunur. Bu, tümörün doğasının tam olarak anlaşılmasını gerçekten zorlaştırmaktadır. Beyin tümörlerini saptamak için en iyi teknik Manyetik Rezonans Görüntülemedir (MRG). Taramalar yoluyla büyük miktarda görüntü verisi üretilir. Bu görüntüler radyolog tarafından incelenir ancak manuel inceleme, beyin tümörlerinde yer alan karmaşıklık düzeyi ve özellikleri nedeniyle hataya açık olabilir. Bu nedenle beyin tümörlerinin erken tespiti ve doğru sınıflandırılması, tıbbi görüntüleme alanında önemli bir araştırma alanıdır ve bu yönüyle hastaların hayatını kurtarmak için en uygun tedavi yönteminin seçilmesine yardımcı olmaktadır.

Bu tez çalışmasında beyin tümörü MR görüntüleri veri setleri kullanılmıştır. Veri setleri Kaggle web sitesinden elde edilen kullanıma açık beyin MR görüntüleri içermektedir. İlk veri seti 7023 MR görüntüsünden, ikinci veri seti 3264 MR görüntüsünden oluşmaktadır ve veri setlerinde dört sınıf bulunmaktadır. Bunlar; glioma tümörü, menenjiyom tümörü, hipofiz tümörü ve tümör olmayan sınıflarıdır. Veri setindeki görüntüler başlangıçta %70 eğitim, %15 test ve %15 doğrulama (validation) verisi olarak her eğitimde rastgele olarak belirlenmiştir.

7023 MR görüntüsü içeren ilk veri setine ait örnek sayısı Tablo 3.1’de açıklanmıştır.

Tablo 3.1: 7023 MR görüntüsü içeren veri seti örnek sayısı (Veri Seti 1)

| Tümör Sınıfı | Eğitim | Test | Doğrulama | Toplam |
|---------------------|---------------|-------------|------------------|---------------|
| Glioma Tümör | 1135 | 243 | 243 | 1621 |
| Meningioma Tümör | 1151 | 247 | 247 | 1645 |
| Pituitary Tümör | 1229 | 264 | 264 | 1757 |
| Tümörsüz | 1400 | 300 | 300 | 2000 |
| Toplam | 4915 | 1054 | 1054 | 7023 |

3064 MR görüntüsü içeren ikinci veri setine ait örnek sayısı Tablo 3.2’de açıklanmıştır.

Tablo 3.2: 3264 MR görüntüsü içeren veri seti örnek sayısı (Veri Seti 2)


| Tümör Sınıfı | Eğitim | Test | Doğrulama | Toplam |
|---------------------|---------------|-------------|------------------|---------------|
| Glioma Tümör | 648 | 139 | 139 | 926 |
| Meningioma Tümör | 655 | 141 | 141 | 937 |
| Pituitary Tümör | 623 | 134 | 134 | 891 |
| Tümörsüz | 350 | 75 | 75 | 500 |
| Toplam | 2276 | 489 | 489 | 3264 |

Tez çalışmasında kullanılan birinci (7023 MR görüntüsünü içeren) ve ikinci (3064 MR görüntüsü içeren) veri setinin birleştirilmiş haliyle oluşturulan yeni veri setine ait örnek sayısı Tablo 3.3’te açıklanmıştır.

Tablo 3.3: 10287 MR görüntüsü içeren birleştirilmiş veri seti örnek sayısı (Veri Seti 1+ Veri Seti 2)

| Tümör Sınıfı | Eğitim | Test | Doğrulama | Toplam |
|------------------|-------------|-------------|-------------|--------------|
| Glioma Tümör | 1783 | 382 | 382 | 2547 |
| Meningioma Tümör | 1806 | 388 | 388 | 2582 |
| Pituitary Tümör | 1852 | 398 | 398 | 2648 |
| Tümörsüz | 1750 | 375 | 375 | 2500 |
| Toplam | 7191 | 1543 | 1543 | 10287 |

Birleştirilmiş yeni veri setinin içerdiği beyin MR görüntüleri içerisinde her sınıfa ait 3 örnek Şekil 3.1’de gösterilmiştir.



Şekil 3.1: Glioma Tümör, Meningioma Tümör, Pituitary Tümör ve Tümörsüz beyin MR Görüntü Örnekleri

Glioma tümörü: Glioma, beyinde veya omurilikte başlayan hücrelerin büyümesidir. Bir gliomadaki hücreler, glial hücreler olarak adlandırılan sağlıklı beyin hücrelerine benzer. Glial hücreler sinir hücrelerini çevreler ve işlev görmelerine yardımcı olur. Bir glioma büyüdükçe, tümör adı verilen bir hücre kütlesi oluşturur.

Meningioma tümörü: Menenjiyomlar, beyni ve omuriliği kaplayan zardan (meninksler) gelişen tümörlerdir. Erişkinlerde en sık görülen primer beyin tümörleridir.

Pituitary tümörü: Hipofiz bezi içindeki hücrelerin anormal büyümesidir. Hipofiz bezi, beynin tabanında hipotalamusun altında bulunan küçük, fasulye büyüklüğünde bir bezdir. Bu tümörlerin bazıları, hipofiz bezinin önemli vücut fonksiyonlarını kontrol eden bazı hormonları çok fazla üretmesine neden olur.

3.1.1. Veri Seti Güç Analizi

Çalışma kapsamında oluşturduğumuz birleştirilmiş veri setinde toplam 10287 insan beyni MR görüntüsü bulunmaktadır. MR görüntülerine ait sınıf dağılımları aşağıdaki gibidir:

- Glioma tümör sınıfına ait: 2547 görüntü,
- Meningioma tümör sınıfına ait: 2582 görüntü,
- Pituitary tümör sınıfına ait: 2500 görüntü,
- Tümör yok sınıfına ait: 2658 görüntü içermektedir.

Veri seti örnek sayısının çalışmamız için yeterlilik durumunu incelemek için güç analizi yapılmıştır. Güç analizi için kullanılan parametreler **Alfa (α)**, **Güç ($1 - \beta$)** ve **Etki büyüklüğü (effect size, f^2)** parametreleridir. Parametrelerin özellikleri aşağı açıklanmıştır.

➤ **Alfa (α):** Yanlış ama pozitif olan hata oranını temsil etmektedir. (Genellikle 0.05 olarak seçilir.)

➤ **Güç (1 - β):** Doğru ve pozitif oranı temsil etmektedir. (Genellikle 0.80 veya 0.90 olarak alınır.)

➤ **Etki büyüklüğü (effect size, f^2):** Cohen tarafından önerilen değerler (Cohen, J., 1992):

- Küçük: 0.02
- Orta: 0.15
- Büyük: 0.35

Etki büyüklüğü (Effect size) parametresi çalışmanın istatistiksel gücünü saptamak için çok önemli bir parametre olarak kabul edilir ve genellikle Cohen'in f^2 katsayısı kullanılmaktadır. Bu parametre değeri seçilirken aşağıdaki kriterlere dikkat edilmesi gereklidir:

Tablo 3.4: Cohen'in f^2 Değerleri ve Açıklamaları

| Etki Büyüklüğü (f^2) | Açıklama | Ne Zaman Kullanılır? |
|--------------------------|---------------------------|---|
| Küçük (0.02) | Küçük etki büyüklüğü | Küçük farkların tespit edilmesi gereken hassas çalışmalar için kullanılmaktadır. |
| Orta (0.15) | Orta düzey etki büyüklüğü | Genellikle standart değer olarak kabul edilir ve çoğunlukla biyomedikal ve görüntü sınıflandırma çalışmalarında kullanılmaktadır. |
| Büyük (0.35) | Büyük etki büyüklüğü | Güçlü sinyallerin tespit edilmesi gereken ve açıkça belirgin farkların bulunduğu çalışmalarda kullanılmaktadır. |

Çalışmadaki sınıflar arasında bulunan farklar belirsizse, küçük etki büyüklüğü (0.02–0.1) tercih edilebilir fakat bu durumda daha fazla veriye ihtiyaç duyulur. Standart sınıflandırma yapılacak çalışmalarda ise çoğunlukla orta etki büyüklüğü (0.15) kullanılmaktadır. Sınıflar arasında bulunan farklar büyükse, büyük etki büyüklüğü (0.35) tercih edilebilir ve bu durumda daha az veri ile çalışmak mümkün olabilmektedir.

Bu tez çalışmasında etki büyüklüğü (effect size, f^2) parametresi seçilirken, genellikle standart değer olarak kabul edilen ve çoğunlukla biyomedikal görüntü sınıflandırma

çalışmalarında kullanılan orta düzey büyüklüğüne sahip etki büyüklüğü (effect size, f^2) tercih edilmiştir. Bunun nedeni MR görüntülerinde bazı tümör tipleri arasında bulunan farkların orta düzey olabilmesi ve klinik olarak anlamlı bir sınıflandırma işlemi yapılabilmesi için bu değerin uygun kabul edilmesidir.

Önerilen veri setinin örnek sayısının yeterliliği analizini yaparken seçtiğimiz orta düzey büyüklüğüne sahip etki büyüklüğü (effect size, f^2) ile G*Power'daki ANOVA için güç analizi yapıldığında ihtiyaç duyulan minimum örneklem büyüklüğünün 488 görüntü olduğu saptanmıştır. Minimum örneklem büyüklüğü, tüm veri seti için toplamda kaç görüntüye ihtiyaç duyulduğunu ifade etmekte olup görüldüğü üzere çalışma kapsamında birleştirilmiş veri setinde bulunan örnek sayısının (10287 görüntü) yeterli olduğu açık bir şekilde görülmüştür.

3.1.2. Veri Artırma Teknikleri

Veri artırma işlemleri, veri kümesinin boyutunu artırarak ve modeli aynı görüntülerin ek varyasyonlarına maruz bırakarak derin öğrenme modellerinin daha iyi genelleştirilmesine yardımcı olan işlemlerdir. Bu işlemler, modelin doğruluğunu artırabilmekte ve aşırı uymayı (overfitting) azaltabilmektedir.

Bu tez çalışmasının temel amaçlarından biri olan artırılmış veriyi elde etmek için; iki ayrı açık erişimli veri setinin birleştirilip etiketlenme işlemlerinden sonra veri artırma teknikleri uygulanarak veri sayısı ve çeşidi artırılmıştır.

Beyin MR görüntüleri üzerinde veri artırma işlemi yapılırken anlamlı ve doğru tekniklerin kullanılabilmesi için Sakarya Üniversitesi Dahili Tıp Bilimleri Bölümü Radyoloji Anabilim Dalı'nda görev yapan Asistan Dr. Muhammet Levent Er'in görüşü alınmıştır. Gerçek hayatta karşılaştıkları beyin MR görüntülerinde yakınlaştırma (zooming) işleminin genellikle uygulanmadığı, dikey olarak çevrilmiş (vertical flip) MR görüntülerine rastlanmadığı ve hastaların beyin MR görüntüleri çekilirken kafaları sabit bir cihazın içinde konumlandırıldığı için görüntülerde gerçek hayatta karşılaşılan kaymaya (width/height shift) çok rastlanılmadığı ifade edilmiştir.

Uygulanması önerilen teknikler ise az dereceli döndürme (rotation) tekniği, beynin sağ ve sol yarım küreleri simetrik olduğundan özellikle mantıklı olabileceğini düşündüğü

yatay çevirme (horizontal flip) tekniđi ve cihaz tipi, hasta hareketi gibi sebeplerle oluřan parlaklık deđiřimlerini telafi etmeye yardımcı olmak amacıyla MR görüntülerine farklı parlaklık (brightness) deđerlerinin de uygulanması teknikleridir. Ayrıca görüntünün içeriđini koruyarak görüntüye paralel kaydırma (shearing) iřlemi de uygulanabilecek diđer bir veri artırma tekniđi olmuřtur. Bu kapsamda uygulanan veri artırma iřlemleri ařađıda açıklanmıřtır.

Uygulanacak veri artırma teknikleri:

- **Ölçeklendirme (Rescaling):** Orijinal görüntüler 0-255'teki RGB katsayılarından oluřur, ancak bu tür deđerler modelin iřlemesi için çok yüksek olacaktır (tipik bir öğrenme oranı göz önüne alındığında), bu nedenle 1/255 ile ölçeklendirmek yerine 0 ile 1 arasındaki deđerleri hedeflendiđi için tüm görüntüleri modele vermeden önce 1/255 oranıyla yeniden ölçeklendirme iřlemi yapılmıřtır.
- **Döndürme (Rotation):** Eğitim sırasında veri kümesindeki görüntüleri yapay ve rastgele küçük dereceli açılarla döndürerek performanslarını test etmek istediđimiz modellerin, görüntü döndürme iřlemlerini daha iyi yapacak şekilde eğitilmesi amaçlanmaktadır.
- **Yatay Çevirme (Horizontal Flip):** Yatay çevirmeli veri büyütme, görüntüleri yatay olarak çevirerek bir veri kümesinin boyutunu artırmak için derin öğrenmede kullanılan bir tekniktir. Bu iřlemin, aynı görüntülerin ek varyasyonlarına maruz bırakarak bir modelin dođruluđunu artırmaya yardımcı olması amaçlanmaktadır.
- **Paralel Kaydırma (Shearing):** Görüntünün biçimini belirli bir eksen boyunca deđiřtirerek farklı bir algı açısı oluřturmak amacıyla uygulanan geometrik artıřtır.
- **Parlaklık (Brightness):** Veri artırma iřlemlerinde parlaklık ayarlaması, gerçek dünyadaki ışık kořullarındaki deđiřiklikleri simüle ederek model genellemesini iyileřtirmek amacıyla uygulanmıřtır.


Uygulanmayacak veri artırma teknikleri:

Ařađıda listelenen veri artırma teknikleri uzman görüşüyle gerçek hayatta klinikte karřılařmadıkları görüntüler üretecekleri ön görüldüđünden tez çalıřması kapsamında uygulanmamıřtır.

- Yakınlaştırma (Zooming)
- -Dikey Çevirme (Vertical Flip)
- -Yükseklik Kaydırma (Height Shift)
- -Genişlik Kaydırma (Width Shift)

Veri artırma teknikleri uygulanmış MR görüntülerine ait rastgele örnekler Şekil 3.2’de verilmiştir.





Şekil 3.2: Veri Setindeki Her Sınıfa ait Artırılmış MR Görüntüsü Örnekleri

3.2. Görüntü Maskeleye Yöntemi

Son dönemde derin öğrenme tabanlı segmentasyon teknikleri, tıbbi görüntü analizinde önemli bir yer edinmiş; özellikle **U-Net** mimarisi, tıbbi görüntü analizi alanında en sık uygulanan modellerden olmuştur. U-Net, sınırlı miktarda etiketli veriyle dahi yüksek doğrulukta segmentasyon gerçekleştirebilmesi ve simetrik encoder–decoder yapısıyla etkili özellik çıkarımı sunması sayesinde, tıbbi görüntüleme çalışmalarında yaygın biçimde kullanılmaktadır. Bu tez kapsamında da, beyin MR görüntüleri üzerinde tümör bölgelerinin otomatik olarak tespit edilmesi amacıyla U-Net tabanlı bir segmentasyon modeli tercih edilmiştir.

Ancak beyin MR görüntülerinde her bir verinin elle etiketlenmiş (ground truth) segmentasyon maskeleriyle donatılması, oldukça zahmetli, ileri seviye bir uzmanlık isteyen ve zaman alıcı bir süreç haline gelmiştir. Bu nedenle, segmentasyon aşamasında doğrudan manuel anotasyonlara dayalı maskeler yerine, "**sözde maskeler**" (**pseudo-mask**) olarak adlandırılan, tam doğruluk içermese de modelin ilgili alanlara odaklanmasını sağlayan tahmini maskeler kullanılmıştır. Bu maskeler, U-Net modelinden elde edilen tahmini çıktılar üzerine uygulanan eşikleme ve morfolojik işlem adımlarıyla sadeleştirilmiş ve kullanılabilir hale getirilmiştir.

Oluşturulan sözde maskeler, sınıflandırma sürecinde modelin tümör bölgesine yönelmesini sağlamak üzere ön işleme aracı olarak kullanılmıştır. Böylece modelin, tüm MR görüntüsünü analiz etmek yerine yalnızca anlamlı anatomik bölgeler üzerinde yoğunlaşması sağlanmış; bu da öğrenme sürecinin verimliliğini artırarak sınıflandırma performansını olumlu yönde etkilemiştir. Bu yöntem, özellikle sınırlı anotasyona sahip veri setleri ile çalışılan durumlarda, transfer öğrenme tabanlı sınıflandırma yaklaşımları için pratik, uygulanabilir ve etkili bir strateji sunmaktadır.

Bu çerçevede, sözde maskelerin kullanımı hem yüksek kaliteli etiket verisine olan ihtiyacı azaltmakta hem de zaman ve kaynak açısından önemli tasarruflar sağlamaktadır. Aynı zamanda, sınıflandırma modeline dikkat odaklı bilgi sunarak genel başarıyı artırmakta ve görüntü işleme alanında etik veya teknik sınırlamaların bulunduğu durumlar için işlevsel bir ön işleme yöntemi olarak değerlendirilmektedir.

Çalışmada beyin MR görüntülerine ait tümör bölgelerinin segment edilmesi amacıyla U-Net tabanlı bir model geliştirilmesi amaçlanmaktadır. U-Net modeli eğitilirken her

bir MR görüntüsüne karşılık gelecek gerçek (ground-truth) segmentasyon maskelerine ihtiyaç duymaktadır. Ancak çalışma için birleştirdiğimiz veri setinde yalnızca ham görüntüler bulunmaktadır. Görüntülerin gerçek (ground-truth) segmentasyon maskelerinin bulunmaması nedeniyle U-Net modelini eğitebilmek amacıyla ön adım olarak sözde (pseudo) maskeler oluşturulmuştur. Elde edilen pseudo maskeler, U-Net modelinin giriş görüntüleriyle eşleştirilerek modelin eğitilmesinde kullanılmıştır.

3.2.1. Sözde (Pseudo) Maskelerin Oluşturulması


MR görüntülerine ait sözde (pseudo) maskeler oluşturulurken görüntü işleme tabanlı Otsu Eşikleme (Thresholding) (Otsu, N., 1975) yöntemi kullanılmış ve bu sözde (pseudo) maskeler her MR görüntüsü için otomatik olarak oluşturulmuştur. Otsu Eşikleme (Thresholding) yöntemi, görüntüde bulunan parlaklık değerlerini ve doku farklılıklarını kullanarak olası tümör bölgelerini ayırt etmeyi amaçlamaktadır. Üretilen sözde maskeler, uzman kişiler tarafından oluşturulan gerçek maskelerin yerine tam olarak geçerse de, modelin temel segmentasyon yeteneği kazanabilmesi adına önemli ve değerli bir başlangıç olarak kabul edilmektedir. Otsu yönteminin avantajı, eşik değerini seçmek için otomatik ve veri odaklı bir yaklaşım sunması ve manuel müdahale ihtiyacını ortadan kaldırmasıdır. Bu sebeple nesne tanıma, kenar algılama ve görüntü segmentasyonu gibi çeşitli görüntü analizi uygulamalarında yaygın olarak kullanılır.

Segmentasyon işlemi yapılırken görüntünün renklerine değil, yoğunluk farklılıklarına odaklanılmaktadır. Bu amaçla sözde maskeler oluşturulurken görüntüler siyah-beyaz (grayscale) biçimde okunmaktadır. Okunan görüntü siyah-beyaz bir ikili (binary) görüntüye dönüştürüldükten sonra Otsu eşikleme yöntemi ile görüntünün piksel yoğunlukları analiz edilerek en uygun eşik değeri otomatik olarak seçilmektedir. Otsu'nun yöntemine göre arka plan ve ön plan arasındaki eşik için mümkün olan her değer incelenir, iki kümenin her birindeki varyansı hesaplanır ve bu varyansların ağırlıklı toplamının en küçük olduğu değer seçilir. Görüntüde piksel değeri, bu eşik değerden büyük ise 255 (beyaz), küçük ise 0 (siyah) yapılır. Bu işlem aracılığıyla ön plan ile arka plan (örneğin tümör bölgesi) birbirinden ayrılmaya çalışılır.

Otsu eşikleme yöntemi ile oluşturulan ikili (binary) maskeler çok gürültülü veya delikli bir yapıya sahip olabilmektedir. Bu durumların düzeltilmesi amacıyla, morfolojik işlemler uygulanmaktadır. Bu morfolojik işlemler: aşındırma (erosion) ve genişletme (dilation) işlemleridir. İşlemlerin amacı sözde maskeler üzerinde oluşan beyaz alanlardaki küçük delikleri kapatmak ve konturları daha düzgün hale



getirmektedir. Şekil 3.3'te Otsu Eşikleme yöntemi ile elde edilmiş sözde (pseudo) maskeler gösterilmiştir.




Şekil 3.3: Örnek Sözde (Pseudo) Mask Görüntüleri

3.2.2 U-Net Tabanlı Segmentasyon Modeli

U-Net, özellikle biyomedikal görüntü segmentasyonu için tasarlanmış bir evrişimli sinir ağı (CNN) mimarisidir. U-Net'in oluşturulması, görüntü içindeki nesnelerin ve sınırların yerini belirlemeye odaklanan görüntü segmentasyonu alanında öncülük yapan çok önemli bir keşif olmuştur ve bu yeni mimari, biyomedikal görüntülerin analizinde muazzam bir değer taşıdığını göstermiştir. Modelin amacı, bir görüntüdeki her pikselin ait olduğu sınıfı (örneğin tümör mü değil mi?) tahmin etmektir. Gerek görüntüdeki bağlamı (neyin nerede olduğu) gerek görüntünün yerel detaylarını (kenarlarını, sınırlarını) yakalamada oldukça iyi performans göstermektedir.

U-Net mimarisi, iki temel bölümden oluşmaktadır. Bu bölümler; iniş (encoder) ve çıkış (decoder) bölümleridir. İniş (encoder) bölümü, konvolüsyon ve havuzlama (max pooling) katmanları aracılığıyla görüntülerden öznitelikleri çıkararak çözünürlüğü düşürürken, görüntünün içeriğine ait bilgileri yoğunlaştırmaktadır. Çıkış (decoder) kısmı ise bu düşük çözünürlüğe sahip öznitelikleri aşamalı olarak yeniden boyutlandırarak diğer yandan ve iniş (encoder) katmanlarından elde edilen detaylı bilgilerle (skip connections) birleştirerek segmentasyon doğruluğunu artırmaktadır. U-Net mimarisinin bu simetrik yapısı sayesinde hem bölgesel detayları hem global bağlamı aynı anda değerlendirerek sınırlı sayıda olan etiketli veriyle dahi yüksek performanslı segmentasyon işlemi gerçekleştirebilmektedir.

Şekil 3.4'te U-Net mimarisine ait görsel yer almaktadır.



Şekil 3.4: U-Net Mimarisi

Kaynak: Ronneberger, O., vd. , 2015

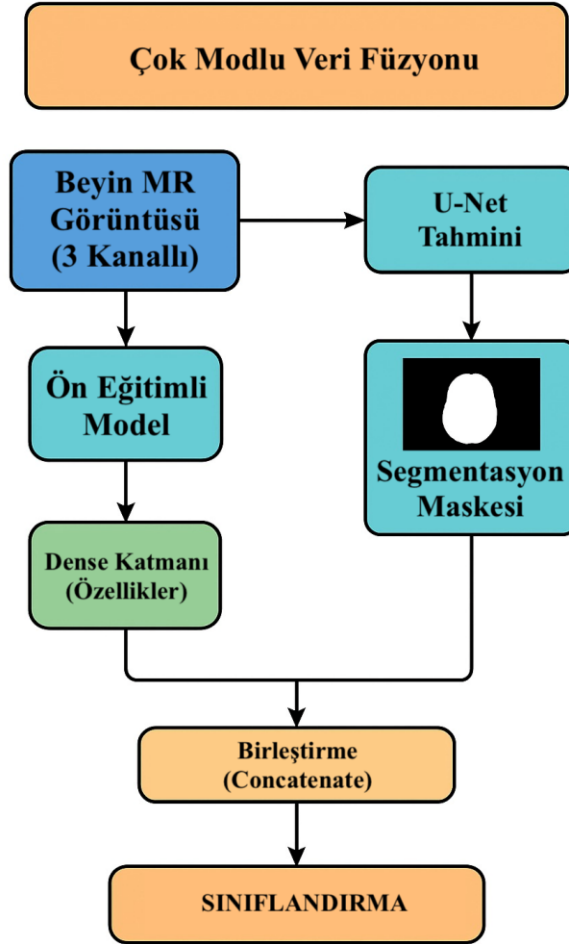
Literatürde bu tip yöntemler zayıf denetimli (**weakly-supervised**) ya da **öz denetimli (self-supervised)** segmentasyon yaklaşımları arasında bulunmaktadır. Özellikle uzman kişiler tarafından görüntü/maske etiketleme işleminin maliyetli olduğu medikal görüntüleme gibi alanlarda sıkça kullanılmaktadır.

Çalışmamızda uyguladığımız U-Net segmentasyon işleminden önce elde edilen sözde (pseudo) masekeler, U-Net modeline ait giriş görüntüleri ile eşleştirilerek modelin eğitiminde kullanılmaktadır. Bu sayede model, etiketi bulunmayan ya da sınırlı etiketli durumlarda bile segmentasyon işlemini yapabilmeyi öğrenmektedir.

beyin MR görüntüleri üzerinde tümör sınıflandırma işlemi yapılırken görüntülerden özellikler çıkarmak için ön eğitilmiş modelin özellik çıkarıcısının yanı sıra U-Net segmentasyon işlemi ile oluşturulan tahmini maskeler de özellik olarak kullanılmıştır. U-Net Segmentasyonunun işleminin teknik detayları Bölüm 3'te 3.2. U-Net Tabanlı Segmentasyon Modeli başlığı altında açıklanmıştır. Modelin sınıflandırma performansını güçlendirmek amacıyla yapılan U-Net segmentasyonu ile özellik

çıkarımı işlemi sonucunda ön eğitilmiş modellerin sınıflandırma performanslarında büyük iyileşmeler olduğu görülmüştür.

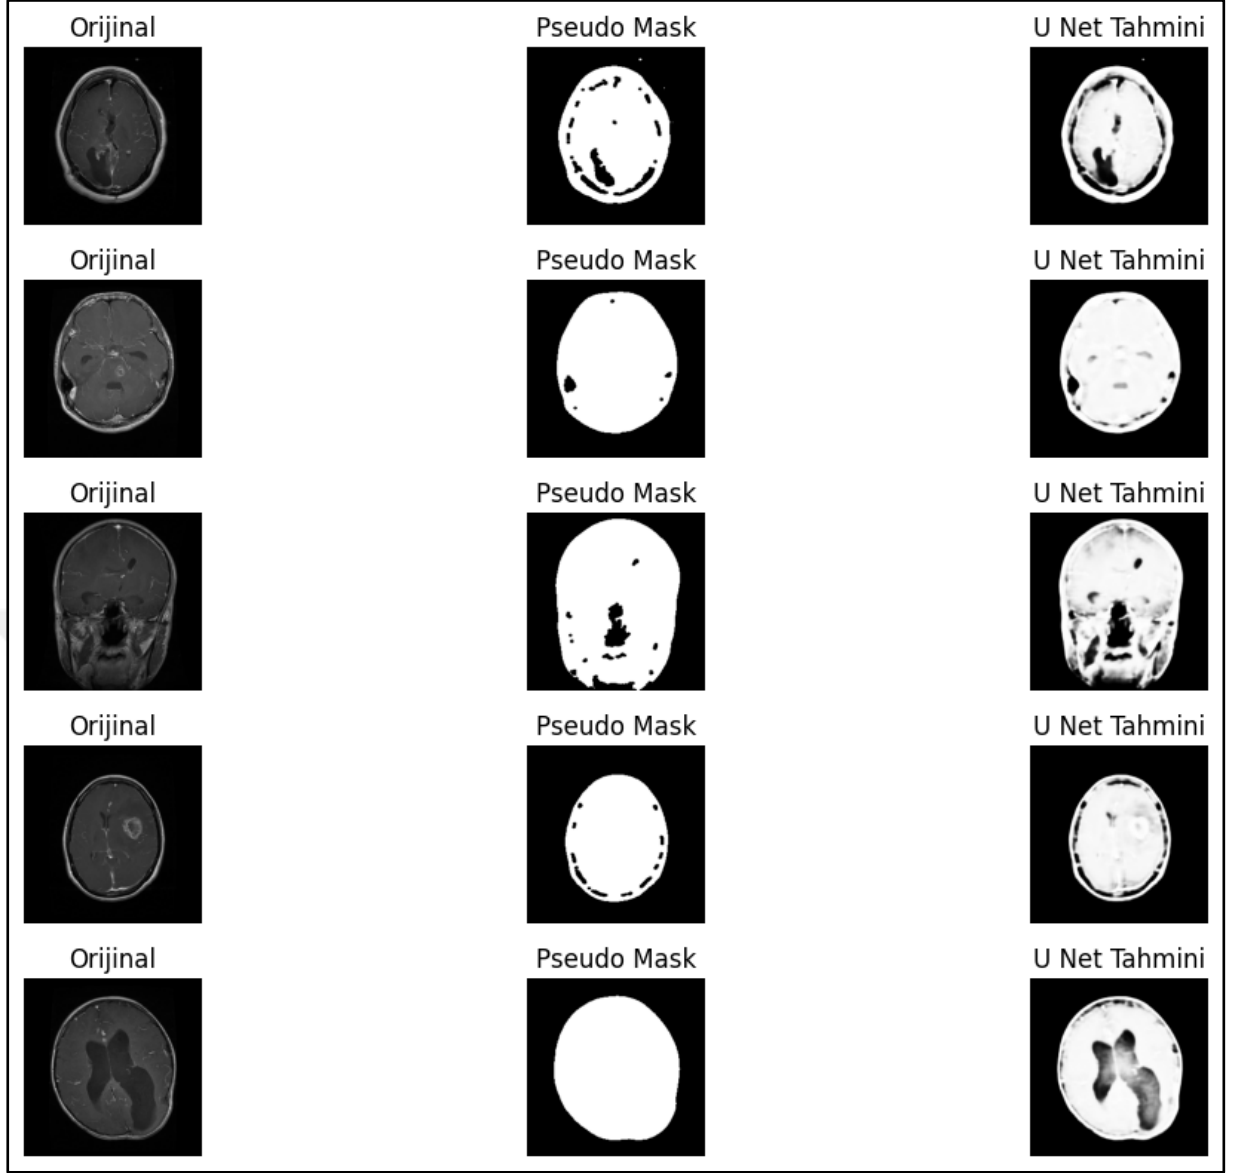
Çok Modlu Veri Füzyonu (Multi-Modal Data Fusion/MMDF); farklı boyut, çözünürlük, tür vb.'ye sahip farklı veri akışlarını birleştirilerek daha anlaşılır veya kullanılabilir bir biçimde bilgi üretme sürecine verilen isimdir. Çalışmamızda beyin MR görüntüleri ön eğitilmiş modellere standart yaklaşım olarak 3 kanal olarak verilmiş ve U-Net ile oluşturulan maskeler ayrı bir katman (dense layer) içerisinde özellikle (feature) olacak şekilde entegre edilmiştir. Sonrasında 3 kanallı beyin MR görüntüsü ve U-Net Tahmini maskesi birleştirilerek (concatenate) son sınıflandırma işlemi gerçekleştirilmiştir. Çok Modlu Veri Füzyonu'na ait görselleştirme (akış diyagramı) Şekil 3.5'te verilmiştir.



Şekil 3.5: U-Net Tabanlı Ön Eğitilmiş Derin Öğrenme Modellerine Ait Çok Modlu Veri Füzyonu Akış Diyagramı

Çalışmamızda önerilen model, sınıflandırma performansını artırmak amacıyla farklı iki veri türünün paralel olarak işlenmesi işlemidir. Modelin ilk giriş katmanında, beyin MR görüntüleri yer alırken, ikinci giriş katmanında U-Net ile tahmin edilen maskeleri bulunmaktadır. Beyin MR görüntüleri, ImageNet veri seti üzerinde önceden eğitilmiş olan ön eğitilmiş derin öğrenme modellerinin mimarisi ile işlenerek derin özellik çıkarımı gerçekleştirilmektedir. U-Net tahmin maskesi görüntüleri ise ilk olarak düzleştirilmekte (Flatten), sonrasında tam bağlı (Dense) katmanlarından geçerek anlamlı bir özellik temsiline dönüştürülmektedir. İki farklı girişten elde edilen bu özellikler Concatenate katmanı aracılığıyla birleştirilmekte ve böylece hem görüntü hem de maske bilgisi ortak bir temsilde bir araya getirilmektedir. Bu entegre model ile modelin çok sınıflı bir sınıflandırma işlemi yapması beklenmektedir. Bu yapı sayesinde model, görüntü ve maske bilgilerini bir arada değerlendirerek çok daha zengin bir karar mekanizması geliştirmektedir.

Şekil 3.6'da U-Net Tabanlı segmentasyon işlemi sonucunda tahmin edilen maskelenmiş görseller yer almaktadır.



Şekil 3.6: U-Net Segmentasyon İşlemi Sonucu Tahmini Maskelenmiş Görsel Örnekleri

3.3. Ön Eğitimli Transfer Öğrenme Modelleri

Transfer öğrenme, önceden eğitilmiş bir modelin yeni bir problem üzerinde yeniden kullanılmasına denir. Transfer öğrenmesinde, bir makine önceki bir görevden edindiği bilgiyi, başka bir görev hakkında genellemeyi geliştirmek için kullanabilmektedir. Sinir ağları genellikle önceki katmanlardaki kenarları, orta katmandaki şekilleri ve sonraki katmanlardaki bazı göreve özgü özellikleri tespit etmeye çalışır. Transfer öğrenmede ise ilk ve orta katmanlar kullanılarak yalnızca son katmanlar yeniden

eğitilir. Bu durum, başlangıçta eğitildiği görevin etiketli verilerinden yararlanılmasına yardımcı olmaktadır

Transfer öğrenme modellerinin yeniden eğitilmesi ince ayar olarak bilinmektedir. Ancak transfer öğrenmede, yeniden eğitim için belirli katmanların ayrılması gerekmektedir.

Dondurulmuş katmanlar: Yeniden eğitim sırasında yalnız bırakılan ve modelin üzerine inşa edebileceği önceki bir görevden edindiği bilgileri saklayan katmanlardır

Değiştirilebilir katmanlar: İnce ayar sırasında yeniden eğitilen ve böylece bir modelin bilgisini yeni, ilgili bir göreve uyarlayabildiği katmanlardır.

Önceden eğitilmiş (transfer learning) modelleri; eğitim süresinden tasarruf sağlamaları, çoğu durumda sinir ağlarının daha iyi performans göstermeleri ve çok fazla veriye ihtiyaç durmamaları gibi ana avantajları nedeniyle tercih edilen derin öğrenme modellerinden olmaktadır. Geleneksel tanı yöntemlerine kıyasla daha hızlı, daha doğru ve tutarlı sonuçlar elde etmek amacıyla beyin MR görüntülerini sınıflandırmak için ön eğitilmiş transfer öğrenme modelleri kullanılmaktadır.


Bu doğrultuda bu bölümde arttırılmış yeni veri setini eğitmek amacıyla kullanılan radyomik tabanlı önceden eğitilmiş derin öğrenme (transfer learning) modellerinin teorik çerçeveleri ve mimari yapıları açıklanmıştır. Bu tez çalışması kapsamında test edeceğimiz ön eğitilmiş derin öğrenme (transfer learning) modelleri aşağıda listelenmiştir:

- Residual Network (ResNet50)
- GoogLeNet mimarisi + Inception modülleri (InceptionNetV3)
- Visual Geometry Group (VGG19)
- Mobile Networks (MobileNet)
- EfficientNetB3

3.3.1. Residual Network (ResNet50) Modeli

ResNet50 transfer öğrenme modeli, Kalıcı Ağ (Residual Network) anlamına gelen He Kaiming, Zhang Xiangyu, Ren Shaoqing ve Sun Jian tarafından 2015 yılında

yayınlanan "Deep Residual Learning for Image Recognition" adlı makalede tanıtılan belirli bir evrişimli sinir ağı (CNN) türüdür (He vd., 2016). ResNet50, 50 katmanlı bir evrişimli sinir ağıdır ve 48 evrişim katmanı, bir MaxPooling katmanı ve bir ortalama havuzlama katmanından oluşmaktadır. Artık sinir ağları, artık blokları istifleyerek ağlar oluşturan bir yapay sinir ağı türü olarak tanımlanmaktadır. Şekil 3.7’de, bir artık blok (residual block) örneği gösterilmektedir.



Şekil 3.7: Artık Blok Örneği

Kaynak: He, vd., 2016

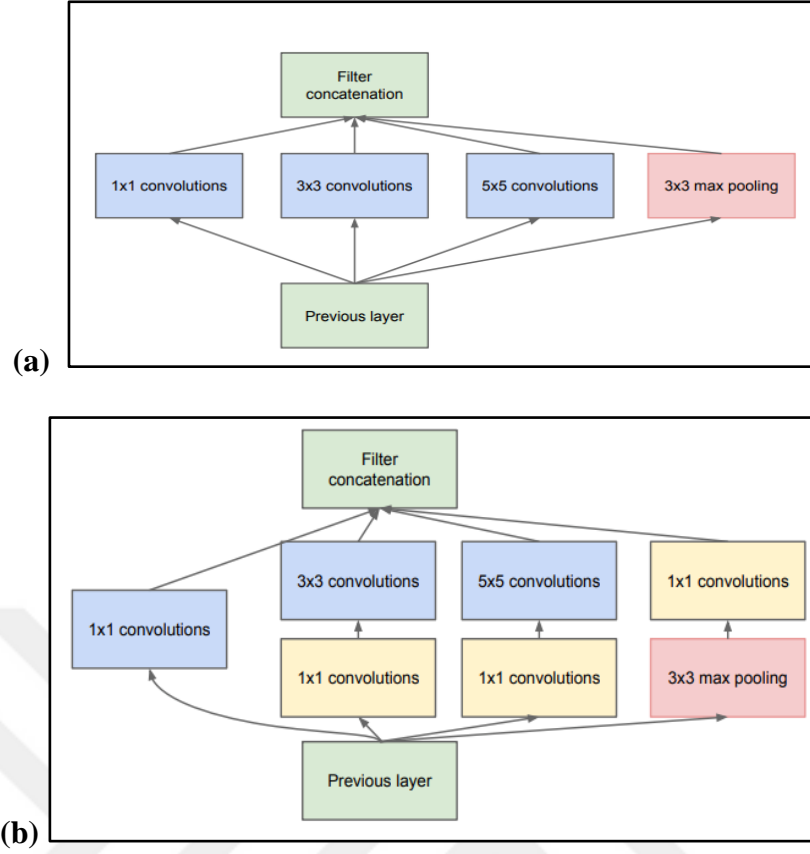
ResNet50 modelinde, derin sinir ağlarının eğitimini kolaylaştırmak için kullanılan artık bloklar, Atlama Bağlantıları (Skip Connections) olarak da bilinen ve bilgilerin bir veya daha fazla katman üzerinden atlamasına olanak tanıyan doğrudan bağlantılar sunmaktadır. Her katmanın girdiyi sırayla yeni bir gösterime dönüştürdüğü geleneksel mimarilerin aksine, artık bloklar, girdinin bir kısmının dönüşümleri atlamasına olanak tanıyan doğrudan bir bağlantı eklemektedir. Bu yaklaşım, ağ derinliği arttıkça ağ performansının düşmesi sorununu çözmeye yardımcı olmaktadır. Artık bloklar, gradyanların ağ genelinde daha verimli bir şekilde yayılmasına izin vererek eğitim sırasında yakınsamayı kolaylaştırmakta ve performanstan ödün vermeden çok daha derin mimarilerin oluşturulmasına olanak tanımaktadır.

ResNet50 modeli,, derin yapısı ve artık blokların kullanımı sayesinde, girdi verilerinden giderek daha soyut ve karmaşık hiyerarşik temsiller öğrenebilmektedir. Ağdaki her katman, kenarlar ve dokular gibi basit özelliklerden şekiller ve nesnelerin

tamamı gibi karmaşık kavramlara kadar farklı soyutlama düzeylerinde belirli özellikleri yakalayabilmektedir. Hiyerarşik temsilleri öğrenme yeteneği, ResNet50'nin görsel verileri daha iyi anlayıp yorumlamasını sağlayarak görüntü sınıflandırma, nesne algılama ve anlamsal segmentasyon gibi bilgisayarlı görme görevlerinde gelişmiş performans sağlamaktadır.

3.3.2. GoogLeNet mimarisi + Inception modülleri (InceptionNetV3) Modeli

InceptionNetV3 transfer öğrenme modeli, görüntü analizi ve nesne algılamaya yardımcı olan ve GoogLeNet için bir modül olarak piyasaya sürülen bir evrişimsel sinir ağıdır. "Going deeper with convolutions" (Szegedy, vd., 2015) başlıklı makalede açıklanan ağ, ilk olarak ImageNet Tanıma Yarışması sırasında tanıtılan Google'a ait Inception Evrişimsel Sinir Ağı'nın üçüncü sürümüdür. InceptionNetV3'ün tasarımı, daha derin ağlara olanak tanırken aynı zamanda parametre sayısının çok fazla olmasını önlemeyi amaçlamaktadır. InceptionNet mimarisinin arkasındaki temel fikir, bir evrişimsel görüntü ağının optimum yerel seyrek yapısının nasıl yaklaştırılabileceğini ve kolayca erişilebilen yoğun bileşenlerle nasıl kapsanabileceğini ele almaktır. InceptionNet mimarisinde yer alan evrişimsel yapı taşları, çeviri değişmezliği varsayımının temelini oluşturmaktadır. Şekil 3.8'de, (a) Inception modülünün temel formunu ve (b) boyut azaltma tekniklerini içeren değiştirilmiş bir sürümünü göstermektedir.



Şekil 3.8: (a) Inception Modülü (ilk sürüm). (b) Boyutluluğu azaltmak için tasarlanmış Inception modülü.

Kaynak: Szegedy, vd., 2015

InceptionNetV3, görüntü tanıma ve sınıflandırma görevleri için güçlü bir derin öğrenme modelidir ve karmaşık görsel verilerin doğru ve verimli bir şekilde analiz edilmesini sağlar. Karmaşık görsel verileri verimli bir şekilde analiz etme ve doğru sonuçlar sağlama yetenekleriyle bilinen Inception model ailesinin bir parçasıdır ve ayrıca InceptionNetV3 modeli sınırlı verilerle yeni problemleri çözmek için önceden eğitilmiş modellerden yararlanan bir teknik olan transfer öğrenmesinde de kullanılmıştır.

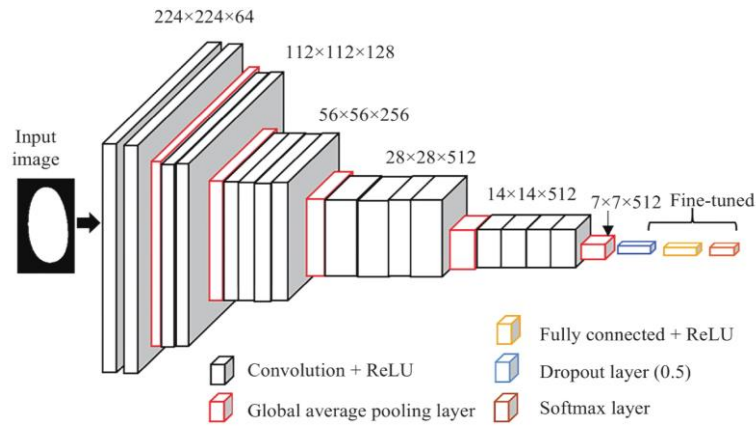
Evrışimsel katmanlar, havuzlama katmanları ve tam bağlantılı katmanlardan oluşurken InceptionNetV3 modeli CNN mimarisinin özel bir örneğidir. Model, karmaşık görsel verilerin verimli analizi ve farklı çekirdek boyutlarına ve derinliklerine sahip birden fazla paralel evrışimsel katman kullanılarak elde edilen doğru sonuçlarla bilinmektedir. Bu katmanlar, giriş görüntülerindeki kenarlar, dokular ve şekiller gibi farklı özellikleri yakalamak üzere tasarlanmıştır. Model daha sonra bu katmanların

çıktılarını birleştirerek giriş görüntüsünün sınıfı veya kategorisi hakkında tahminler yapar. Ayrıca InceptionNetV3, eğitim verimliliğini ve genelleme yeteneklerini artırmak için normalleştirme (normalization) ve bırakma (dropout) gibi teknikler kullanmaktadır.

3.3.3. Visual Geometry Group (VGG19) Modeli

VGG, Visual Geometry Group tarafından geliştirilen, çok katmanlı standart bir derin Evrişimsel Sinir Ağı (CNN) mimarisidir. "Derin", 19 evrişimsel katmandan oluşan VGG-19 adlı mimarideki katman sayısını ifade eder. Derin bir sinir ağı olarak geliştirilen VGGNet, ImageNet'in ötesinde birçok görev ve veri kümesinde temel değerleri aşmakta ve halen en popüler görüntü tanıma mimarilerinden biri olarak kabul edilmektedir. 16 katmanı destekleyen VGG modeli veya VGGNet, Oxford Üniversitesi'nden A. Zisserman ve K. Simonyan tarafından önerilen bir evrişimsel sinir ağı modeli olan VGG16 olarak da anılmaktadır. Bu araştırmacılar (Simonyan ve Zisserman, 2014), modellerini "Very Deep Convolutional Networks for Large-Scale Image Recognition" başlıklı araştırma makalesinde yayınlamışlardır. VGG19 modeli (VGGNet-19), 19 katmanı desteklemesi dışında VGG16 ile aynı mantıkla çalışır. "16" ve "19", modeldeki ağırlık katmanlarının (evrişimsel katmanlar) sayısını temsil eder. Bu, VGG19'un VGG16'nın aksine üç ek evrişimsel katmana sahip olduğu anlamına gelmektedir.

Şekil 3.9'da VGG19 modeli mimarisi görüntüsü bulunmaktadır.



Şekil 3.9: VGG19 Modeli Mimarisi

Kaynak: Shyamalee ve Meedeniya, 2022

VGG19, derin evrişimsel sinir ağı (CNN) mimarileri içerisinde, özellikle görsel tanıma görevlerinde yüksek doğruluk oranlarıyla öne çıkan etkili bir yapı olup daha derin bir mimari aracılığıyla sınıflandırma başarımını artırmayı amaçlamaktadır. Adından da anlaşılacağı üzere toplam 19 katmandan oluşan bu yapıda; 16 evrişim katmanı ile birlikte ve 3 tam bağlantılı katman bulunmaktadır. Mimari açıdan dikkat çeken temel özellik, tüm evrişim katmanlarında standart olarak 3×3 boyutlarında filtrelerin ve 1 birimlik kaydırma (stride) değerinin tercih edilmesidir. Bu sistematik ve sade yaklaşım, modelin derinliğini artırırken aynı zamanda parametre sayısının kontrol altında tutulmasını ve eğitilebilirliğin korunmasını sağlamaktadır.

VGG19'un yapısı, evrişim katmanlarından elde edilen düşük seviyeli özellik haritalarını aşamalı olarak daha soyut ve yüksek düzeyde temsillere dönüştürmektedir. Bu süreçte, belirli katmanlardan sonra uygulanan maksimum havuzlama (max pooling) işlemleriyle uzamsal boyutlar azaltılırken, önemli bilgi öğeleri korunur. Ağın son bölümünde, üç adet tam bağlantılı katman yer almaktadır. Bu katmanlardan ilk ikisi 4096 nöron içerirken, son katman, gerçekleştirilecek görevdeki sınıf sayısına bağlı olarak değişen sayıda nörona sahiptir. Bu son katmanda kullanılan softmax aktivasyon fonksiyonu, sınıflandırma kararının verilmesini sağlar.

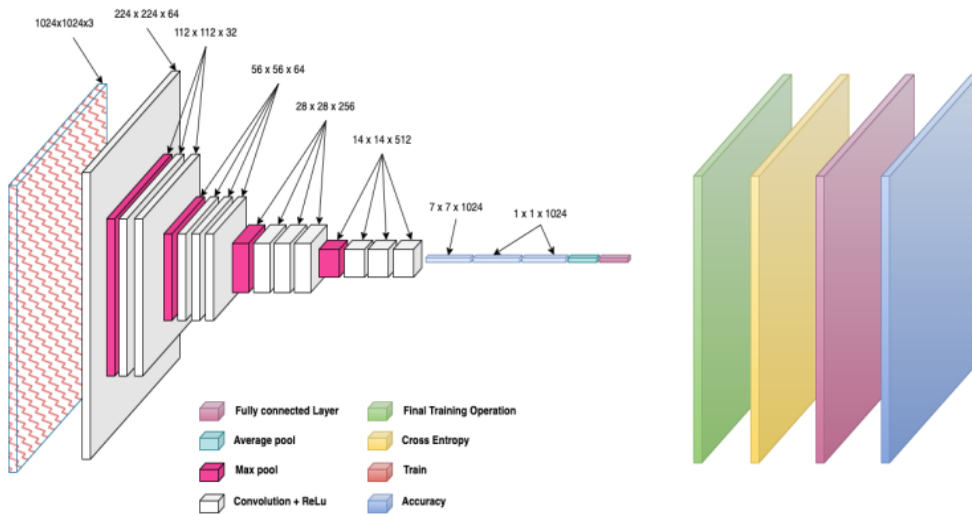
VGG19'un yüksek başarımlı düzeyi, özellikle modelin derin yapısının sağladığı güçlü temsil öğrenme kapasitesiyle ilişkilendirilmektedir. Ayrıca, mimarinin sistematik ve modüler tasarımı, farklı görsel tanıma problemlerine yönelik transfer öğrenme senaryolarında yaygın biçimde kullanılmasına olanak tanımaktadır.

3.3.4. Mobile Networks (MobileNet) Modeli

MobileNet, sınırlı işlem gücüne sahip mobil ve gömülü sistemlerde etkin biçimde çalışmak üzere tasarlanmış, hafif ve yüksek verimlilik sunan bir derin sinir ağı mimarisidir. 2017 yılında Howard (Howard, vd., 2017) diğer araştırmacılar tarafından önerilen bu model, geleneksel evrişimsel sinir ağlarına göre hem daha düşük hesaplama maliyetine sahiptir hem de daha az sayıda parametre içerir. Bu yönüyle, kaynak tüketiminin kritik olduğu ortamlarda derin öğrenme uygulamaları için uygulanabilir bir seçenek olarak dikkat çekmektedir.

MobileNet mimarisinin temelini oluşturan yapı taşı, derinlik ayrık evrişim (depthwise separable convolution) olarak adlandırılan özel bir evrişim türüdür. Bu yaklaşım, klasik evrişim işlemini iki aşamaya ayırarak uygulanmaktadır: İlk aşamada her bir giriş kanalına yalnızca bir filtre uygulanmakta ve bu süreç derinlik bazlı evrişim olarak adlandırılmaktadır. Ardından gelen nokta bazlı evrişim (pointwise convolution) ise 1×1 boyutunda filtrelerle gerçekleştirilen birleştirme işlemiyle, kanal bazında çıkarılan özellikleri bütüncül bir özellik haritasına dönüştürmektedir. Bu iki aşamalı yapı, işlem süresini ve parametre sayısını ciddi oranda azaltmakta; buna rağmen doğruluk oranlarında kayda değer bir düşüş yaşanmadan başarılı sonuçlar elde edilmesini sağlamaktadır.

MobileNet'in bir diğer önemli özelliği, modelin farklı donanım ve uygulama senaryolarına uyarlanmasını mümkün kılan ölçeklenebilirlik mekanizmalarıdır. Bu bağlamda iki temel hiperparametreden biri olan genişlik çarpanı (width multiplier), katmanlardaki filtre sayısını azaltarak modelin genel parametre yükünü düşürürken; çözünürlük çarpanı (resolution multiplier), giriş görüntülerinin boyutlarını küçülterek toplam hesaplama gereksinimini azaltmaktadır. Bu sayede, modelin daha hızlı çalışması sağlanmakta ve enerji verimliliği açısından avantajlar elde edilmektedir. Şekil 3.10'da MobileNet modeli mimarisi görüntüsü bulunmaktadır.



Şekil 3.10. MobileNet Modeli Mimarisi

Kaynak: Howard, vd., 2017

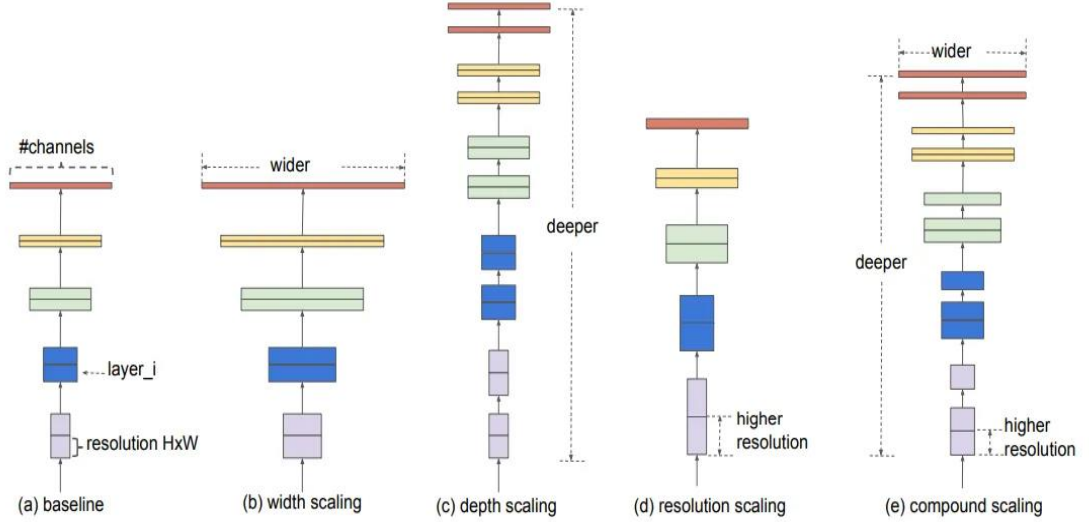
Genel olarak deęerlendirildięinde, MobileNet mimarisi; mimari sadelięi, parametre verimlilięi ve dūřuk hesaplama maliyeti sayesinde, nesnelerin tanınması, gōruntülerin zamanlı iřlenmesi ve yūz algılaması gibi uygulamalarda yaygın olarak kullanılmaktadır. Őzellikle kaynakların kısıtlı olduęu gōmūlū sistemler ve mobil cihazlar gibi platformlarda derin Őęrenmenin uygulanabilirlięini artırması bakımından, modern yapay zeka uygulamaları arasında oldukęa Őnemli bir yere sahiptir.

3.3.5. EfficientNetB3 Modeli

EfficientNet modeli, Mingxing Tan ve Quoc V. Le tarafından (Tan ve Le, 2019) "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks" isimli makalelerinde Őnerilmiřtir. EfficientNets, son teknoloji doęruluk saęlayan, ancak Őnceki modellerden ęok daha kūęuk ve daha hızlı olan bir gōruntū sınıflandırma modelleri ailesi olarak tanımlanabilir.

Tūm sinir aęlarında olduęu gibi, CNN'lerin tasarlanmasındaki kilit konulardan biri modelin Őlęeklendirilmesidir, yani daha iyi doęruluk saęlamak ięin model boyutunun nasıl artırılacaęına karar verilmesidir. Google, bu sorunu dikkate alarak 2019'da yeni bir CNN ailesi olan EfficientNet ile ilgili bir makale yayınlamıřtır. Bu CNN'ler GPipe gibi son teknoloji modellere kıyasla yalnızca daha iyi doęruluk saęlamakla kalmayıp aynı zamanda parametreleri ve FLOPS (Saniyede Kayan Nokta İřlemleri) manifoldunu azaltarak modellerin verimlilięini de artırmaktadırlar.

řekil 3.11'de EfficientNet modeli ait mimari gōrselleřtirilmiřtir.



Şekil 3.11: EfficientNet Modeli Ölçeklendirmesi. (a) bir temel ağ örneği (b)-(d) ağın sadece bir boyutunu artıran geleneksel ölçeklendirme (genişlik, derinlik veya çözünürlük olarak) (e) her üç boyutu da sabit bir oranla eşit şekilde ölçeklendiren önerilen bileşik ölçeklendirme yöntemi

Kaynak: Tan ve Le ., 2019

EfficientNet, standart CNN mimarisini temel alarak yeni bir model ölçekleme yaklaşımı sunmaktadır. Araştırmacılar, modeli birden fazla boyutta (genişlik, derinlik ve çözünürlük) eşit olarak ölçeklendirerek, hesaplama kaynaklarında orantısız bir artış gerektirmeden performansta önemli kazanımlar elde edebileceklerini saptamışlardır.

Genişlik ölçekleme, ağın her bir evrimsel katmanındaki kanal sayısını artırmayı içerir. Bu, ağın giriş verilerindeki daha karmaşık örüntüleri öğrenme kapasitesini artırmaktadır.

Derinlik ölçekleme, ağa daha fazla evrimsel katman eklemeyi içerir. Bu, ağın giriş verilerinden daha soyut ve karmaşık özellikler öğrenmesini sağlamaktadır.

Çözünürlük ölçekleme, giriş görüntülerinin boyutunu artırmayı içerir. Bu, ağın girdi verilerindeki daha ayrıntılı ayrıntıları yakalamasını sağlar; bu da özellikle nesne algılama ve segmentasyon görevleri için önemli olduğu düşünülmektedir..

EfficientNet, bu üç ölçekleme tekniğini yeni bir şekilde birleştirmekte ve her teknik modelin genel performansına katkıda bulunmaktadır.

DÖRDÜNCÜ BÖLÜM

BULGULAR VE TARTIŞMA

4.1. Önceden Eğitilmiş Derin Öğrenme Modelleri Test Sonuçları

Bu tez çalışmasında uygulanan önceden eğitilmiş derin öğrenme modellerinin (ResNet50, InceptionNetV3, VGG19, MobileNet ve EfficientNetB3) test sonuçları bu bölümde raporlanmıştır.

Her modele ait test sonuçları için; eğitim turu (epoch) sayısı, kayıp (loss) değeri, doğruluk (accuracy) değeri, doğrulama kaybı (validation loss) değeri, doğrulama doğruluğu (validation accuracy) değerleri hesaplanmıştır. Ayrıca her modelin test sonucuna ait karmaşıklık matrisleri çizdirilmiş olup sınıflandırma değerlendirme ölçütleri (precision, recall, f1-score ve support) saptanmıştır.

Sınıflandırma metriklerinin açıklamaları ve hesaplama formülleri aşağıda açıklanmıştır.

- **Doğruluk (Accuracy):** Doğruluk, bir makine öğrenimi modelinin sonucu ne sıklıkla doğru tahmin ettiğini ölçen bir ölçümdür. Bu metrik, doğru tahmin sayısının toplam tahmin sayısına bölünmesiyle hesaplanmaktadır. Aşağıda doğruluk değerini (accuracy) hesaplama formülü verilmiştir.

$$Accuracy = \frac{TN + TP}{TN + FP + TP + FN}$$

- **Kesinlik (Precision):** Kesinlik, doğru sınıflandırılan Pozitif örnek sayısının, Pozitif olarak sınıflandırılan toplam örnek sayısına (doğru veya yanlış) oranı olarak hesaplanmaktadır. Bu metrik, modelin bir örneği pozitif olarak sınıflandırma doğruluğunu ölçmektedir. Aşağıda kesinlik (precision) değerini hesaplama formülü verilmiştir.

$$Precision = \frac{TP}{TP + FP}$$

- **Duyarlılık (Recall):** Geri çağırma, bir makine öğrenimi modelinin veri kümesindeki tüm gerçek pozitif örneklerden pozitif örnekleri (gerçek pozitifleri) ne sıklıkla doğru şekilde belirlediğini ölçen bir ölçümdür. Aşağıda duyarlılık (recall) değerini hesaplama formülü verilmiştir.

$$Recall = \frac{TP}{TP + FN}$$

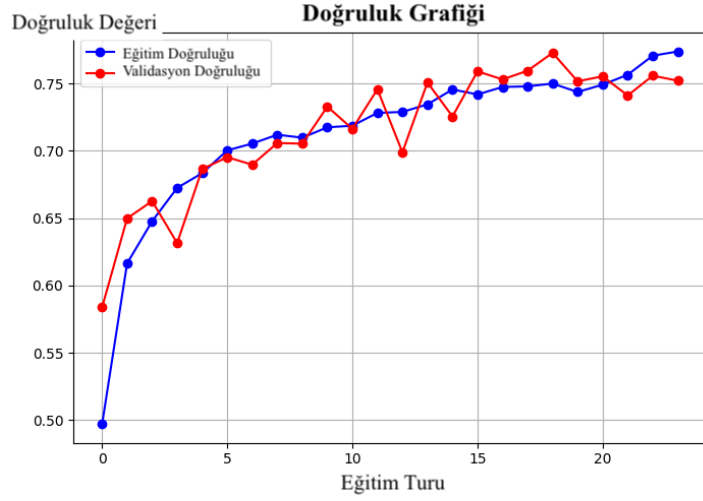
- **F1 Skoru (F1 Score):** F1 puanı, bir modelin tahmin becerisini, doğrulukla yapılan genel performans yerine sınıf bazında performansını ayrıntılı olarak değerlendiren alternatif bir makine öğrenimi değerlendirme metriğidir. F1 puanı, bir modelin hassasiyet ve geri çağırma puanları olmak üzere iki rakip metriği bir araya getirerek, literatürde yaygın olarak kullanılmasını sağlamıştır. Aşağıda F1 Skoru (F1 Score) değerini hesaplama formülü verilmiştir.

$$F1\ Score = 2 * \frac{Precision * Recall}{Precision + Recall}$$

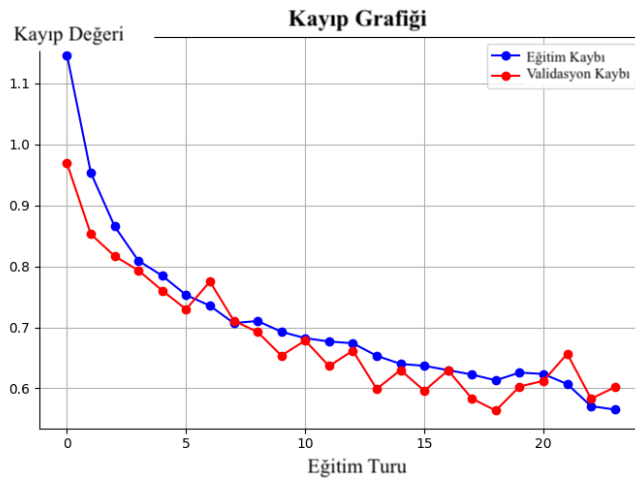
4.1.1. Residual Network (ResNet50) Modeli Deneysel Sonuçları

ResNet50 ön eğitilmiş derin öğrenme modeli, birleştirilmiş ve veri artırma teknikleri (ölçeklendirme (rescaling), döndürme (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) ile artırılmış beyin MR görüntüleri veri setine uygulanmıştır. Modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

ResNet50 modeli 24. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.1’de gösterilmiştir.



(a)



(b)

Şekil 4.1: ResNet50 Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Validasyon Doğruluğu Grafiği ve (b) Eğitim/Validasyon Kaybı Grafikleri

ResNet50 modeline ait eğitim, validasyon ve test doğruluğu değerleri Tablo 4'te sunulmuştur.

Tablo 4.1: ResNet50 Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri

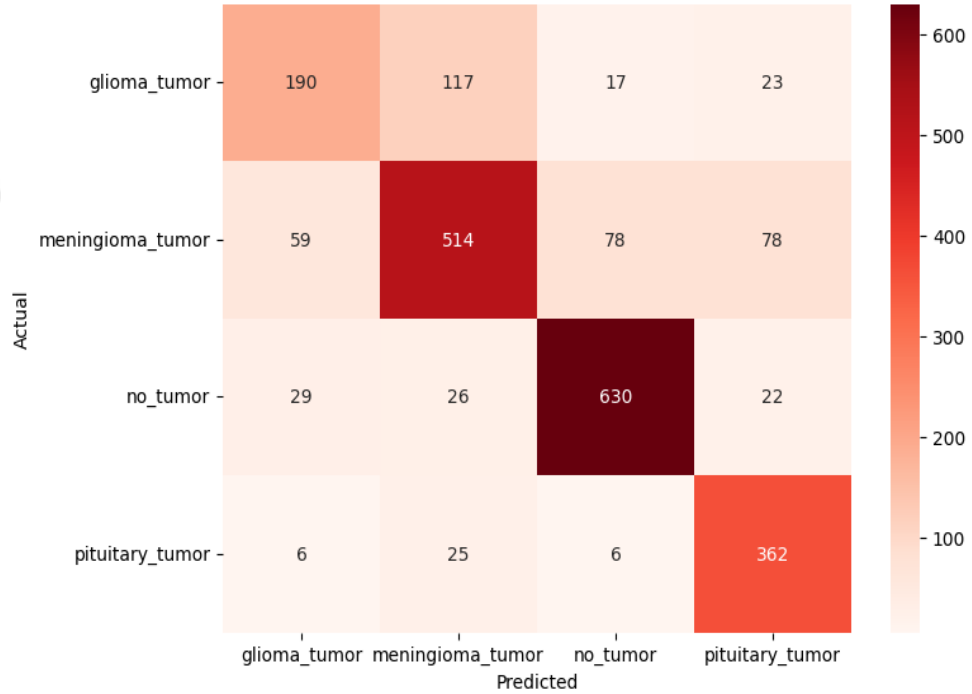
| ResNet50 | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.7738 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.7522 |
| Test Doğruluğu (Test Accuracy) | 0.7773 |

ResNet50 modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.2’de sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.67 | 0.55 | 0.60 | 347 |
| meningioma_tumor | 0.75 | 0.71 | 0.73 | 729 |
| no_tumor | 0.86 | 0.89 | 0.88 | 707 |
| pituitary_tumor | 0.75 | 0.91 | 0.82 | 399 |
| accuracy | | | 0.78 | 2182 |
| macro avg | 0.76 | 0.76 | 0.76 | 2182 |
| weighted avg | 0.77 | 0.78 | 0.77 | 2182 |

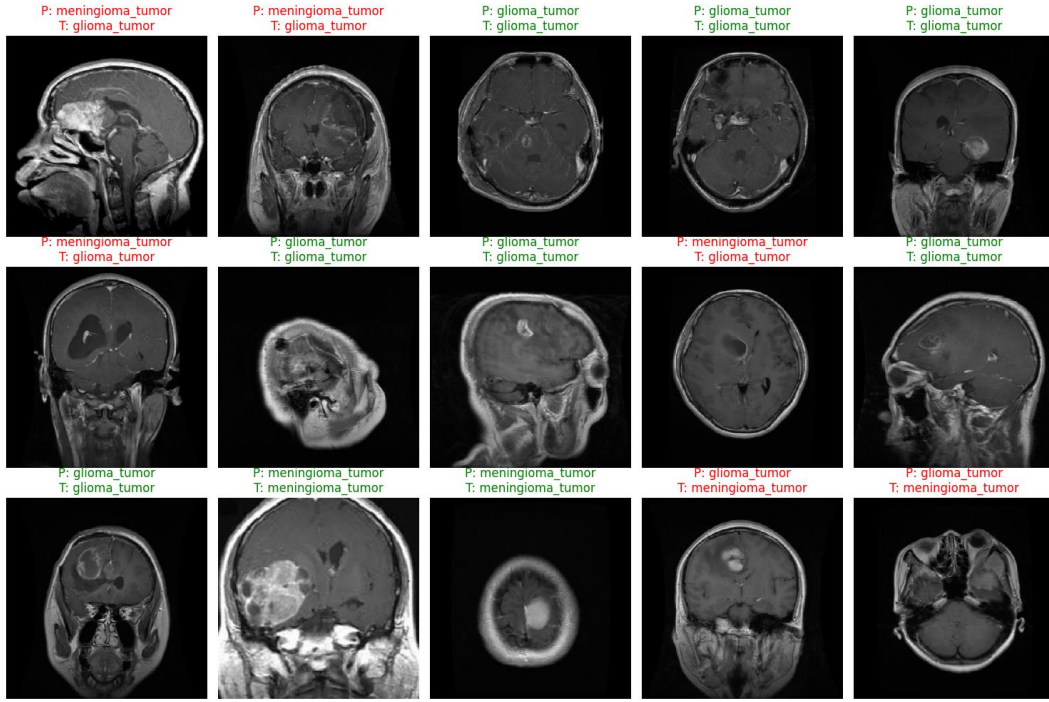
Şekil 4.2: ResNet50 Modeline ait Sınıflandırma Raporu

ResNet50 modeline ait karmaşıklık matrisi ise Şekil 4.3’te verilmiştir.



Şekil 4.3: ResNet50 Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

ResNet50 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.4’te verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir.

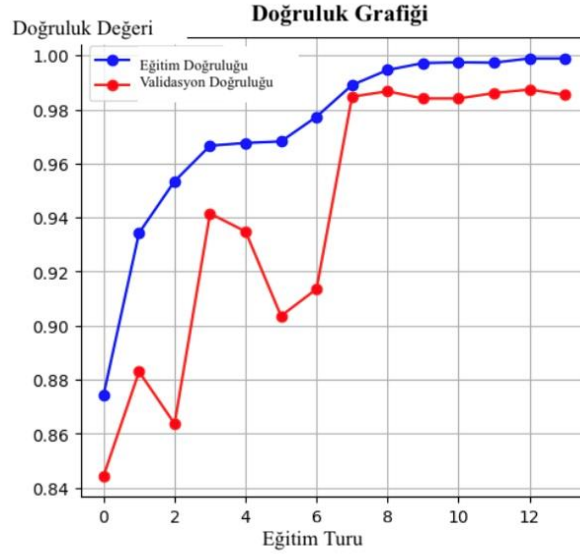


Şekil 4.4: ResNet50 Modeline ait Beyin Tümörü Tahmin Görselleştirmesi

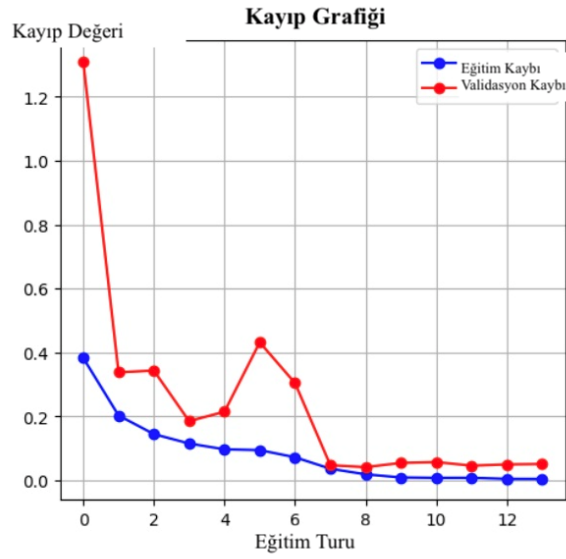
4.1.2. GoogLeNet mimarisi + Inception modülleri (InceptionNetV3) Modeli Deneysel Sonuçları

InceptionNetV3 (GoogLeNet mimarisi + Inception modülleri) ön eğitilmiş derin öğrenme modeli, birleştirilmiş ve veri artırma teknikleri (ölçeklendirme (rescaling), döndürme (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) ile artırılmış beyin MR görüntüleri veri setine uygulanmıştır. Modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

InceptionNetV3 modeli 14. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.5'te gösterilmiştir.



(a)



(b)

Şekil 4.5: InceptionNetV3 Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

InceptionNetV3 modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.2'de sunulmuştur.

Tablo 4.2: InceptionNetV3 Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| InceptionNetV3 | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9989 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9854 |
| Test Doğruluğu (Test Accuracy) | 0.9907 |

InceptionNetV3 modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.6’da sunulmuştur.

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| Glioma | 0.97 | 0.97 | 0.99 | 231 |
| Meningioma | 0.98 | 0.97 | 0.98 | 258 |
| Pituitary | 0.99 | 0.98 | 0.99 | 250 |
| No Tumor | 1.00 | 0.98 | 0.99 | 266 |
| accuracy | | | 0.99 | 1005 |
| macro avg | 0.99 | 0.99 | 0.99 | 1005 |
| weighted avg | 0.99 | 0.99 | 0.99 | 1005 |

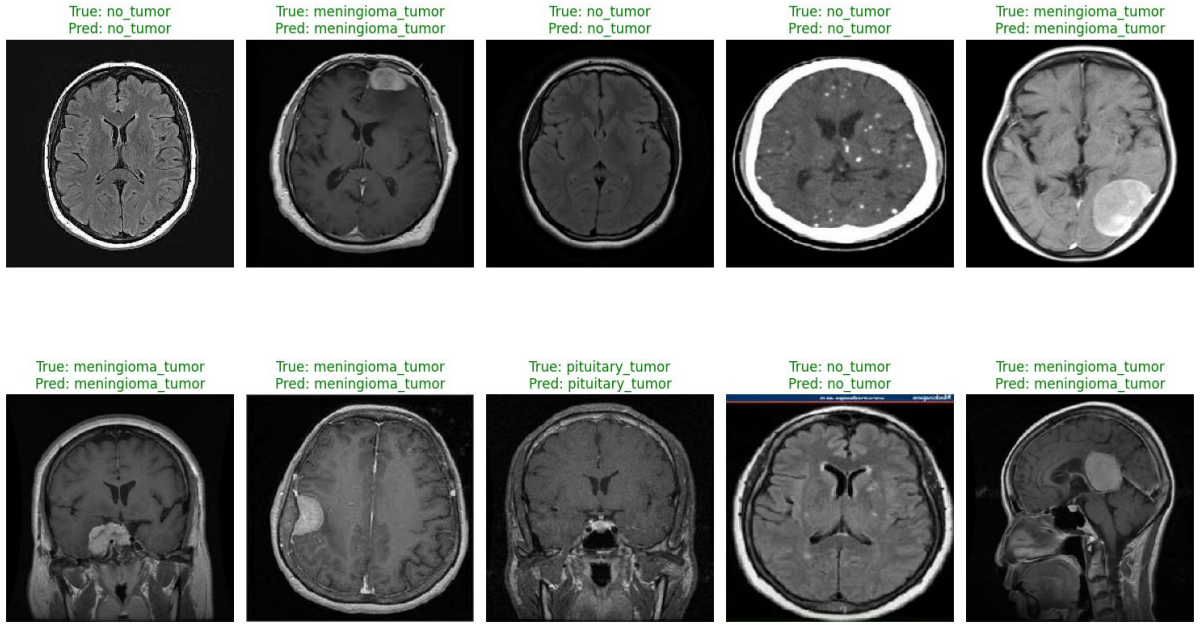
Şekil 4.6: InceptionNetV3 Modeline ait Sınıflandırma Raporu

InceptionNetV3 modeline ait karmaşıklık matrisi Şekil 4.7’de verilmiştir.



Şekil 4.7: InceptionNetV3 Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

InceptionNetV3 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.8’de verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir.

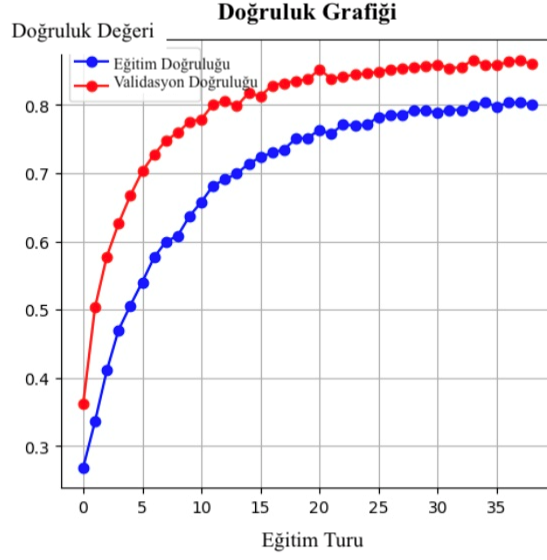


Şekil 4.8: InceptionNetV3 Modeline ait Beyin Tümörü Tahmin Görselleştirmesi

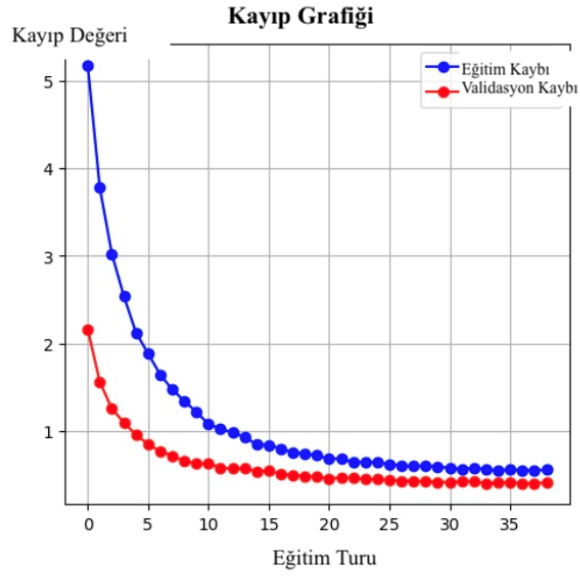
4.1.3. Visual Geometry Group (VGG19) Modeli Deneysel Sonuçları

VGG19 (Visual Geometry Group) ön eğitilmiş derin öğrenme modeli, birleştirilmiş ve veri artırma teknikleri (ölçeklendirme (rescaling), döndürme (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) ile artırılmış beyin MR görüntüleri veri setine uygulanmıştır. Modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

VGG19 modeli 39. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.9’da gösterilmiştir.



(a)



(b)

Şekil 4.9: VGG19 Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

VGG19 modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.3'te sunulmuştur.

Tablo 4.3: VGG19 Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| VGG19 | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.8890 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.8739 |
| Test Doğruluğu (Test Accuracy) | 0.8660 |

VGG19 modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.10'da sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.91 | 0.93 | 0.92 | 375 |
| meningioma_tumor | 0.76 | 0.79 | 0.78 | 388 |
| pituitary_tumor | 0.86 | 0.96 | 0.91 | 399 |
| no_tumor | 0.94 | 0.73 | 0.82 | 346 |
| accuracy | | | 0.86 | 1508 |
| macro avg | 0.87 | 0.86 | 0.86 | 1508 |
| weighted avg | 0.86 | 0.86 | 0.86 | 1508 |

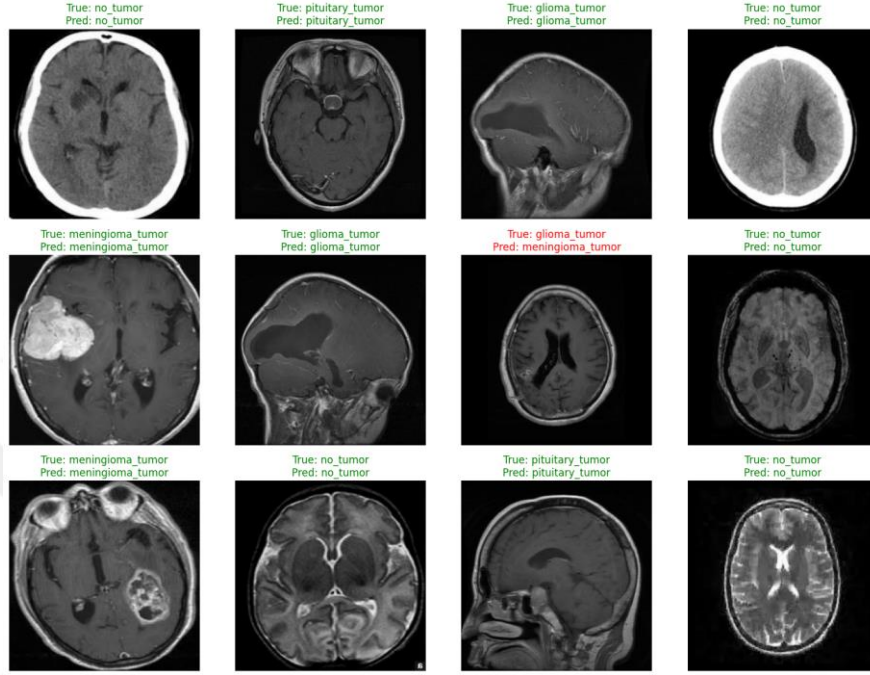
Şekil 4.10: VGG19 Modeline ait Sınıflandırma Raporu

VGG19 modeline ait karmaşıklık matrisi Şekil 4.11'de verilmiştir.



Şekil 4.11: VGG19 Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

VGG19 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.12’de verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir.

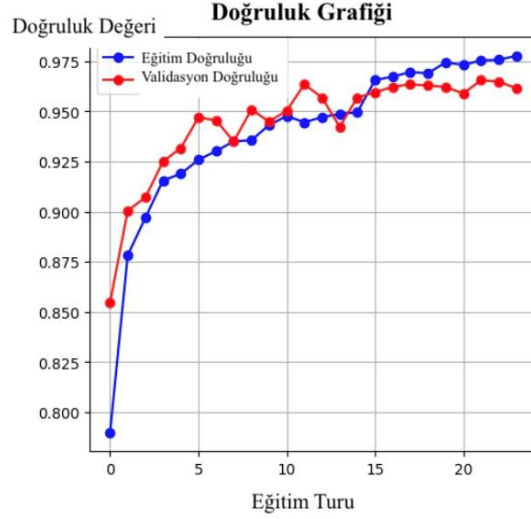


Şekil 4.12: VGG19 Modeline ait Beyin Tümörü Tahmin Görselleştirmesi

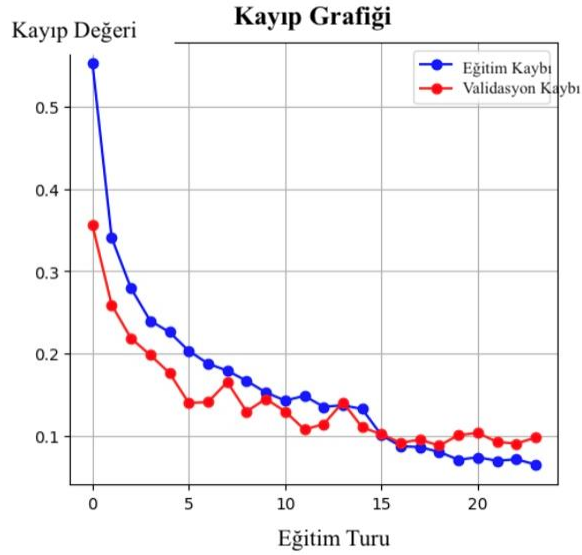
4.1.4. Mobile Networks (MobileNet) Modeli Deneysel Sonuçları

MobileNet (Mobile Networks) ön eğitilmiş derin öğrenme modeli, birleştirilmiş ve veri artırma teknikleri (ölçeklendirme (rescaling), döndürme (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) ile artırılmış beyin MR görüntüleri veri setine uygulanmıştır. Modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

MobileNet modeli 24. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.13’te gösterilmiştir.



(a)



(b)

Şekil 4.13: MobileNet Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

MobileNet modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.4'te sunulmuştur.

Tablo 4.4: MobileNet Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| MobileNet | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9831 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9628 |
| Test Doğruluğu (Test Accuracy) | 0.9662 |

MobileNet modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.14’te sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.95 | 0.92 | 0.94 | 346 |
| meningioma_tumor | 0.93 | 0.95 | 0.94 | 388 |
| no_tumor | 0.99 | 1.00 | 0.99 | 375 |
| pituitary_tumor | 0.99 | 0.99 | 0.99 | 399 |
| accuracy | | | 0.97 | 1508 |
| macro avg | 0.97 | 0.97 | 0.97 | 1508 |
| weighted avg | 0.97 | 0.97 | 0.97 | 1508 |

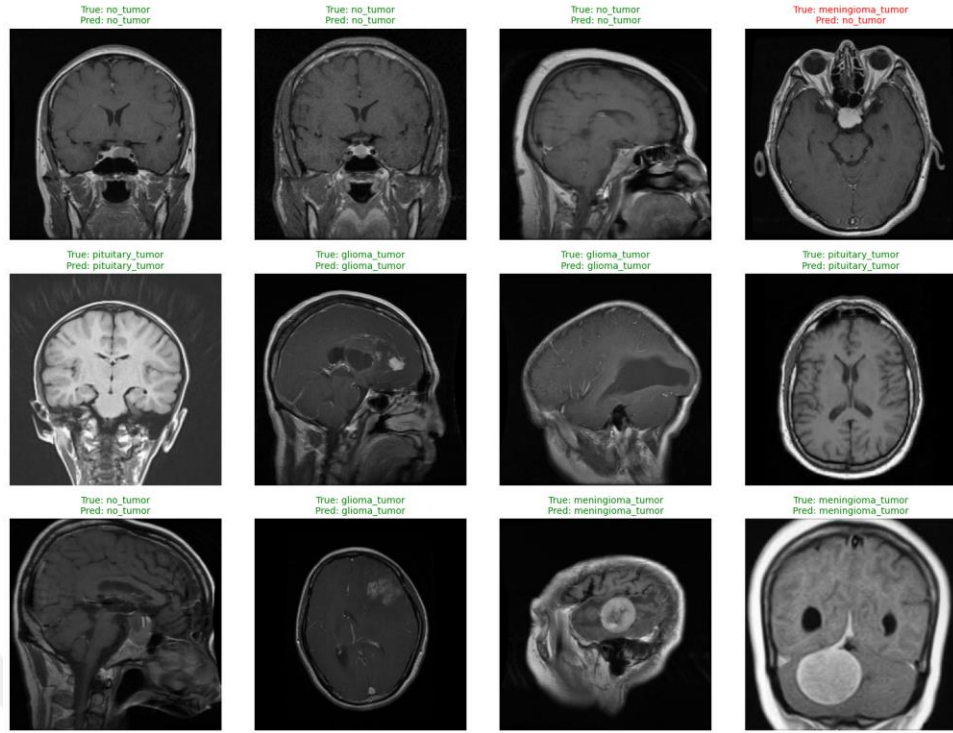
Şekil 4.14: MobileNet Modeline ait Sınıflandırma Raporu

MobileNet modeline ait karmaşıklık matrisi Şekil 4.15’te verilmiştir.



Şekil 4.15: MobileNet Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

MobileNet modeli eğitimi sonucunda tahmin işlemi görselleştirilmesi Şekil 4.16’da verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir.

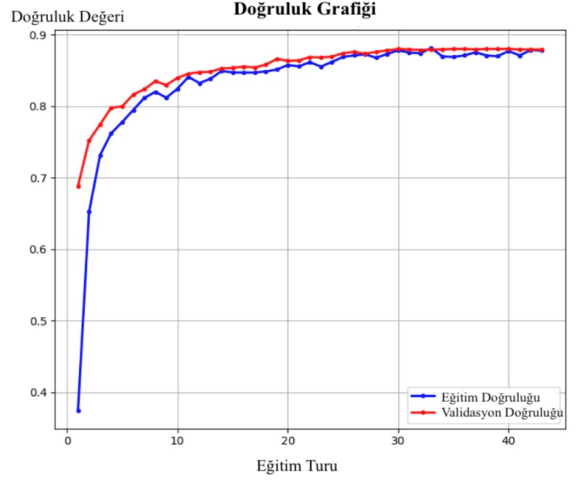


Şekil 4.16: MobileNet Modeline ait Beyin Tümörü Tahmin Görselleştirme

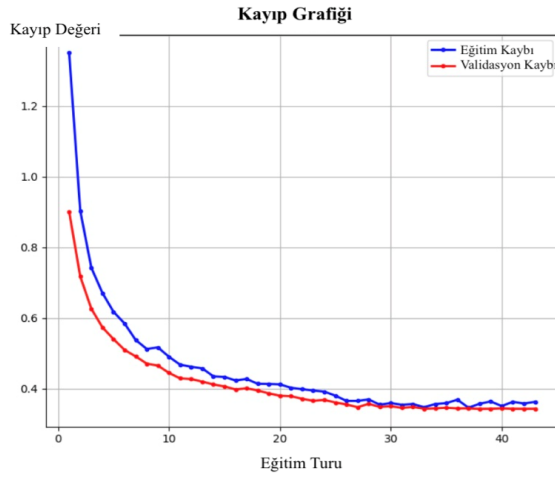
4.1.5. EfficientNetB3 Modeli Deneysel Sonuçları

EfficientNetB3 ön eğitilmiş derin öğrenme modeli, birleştirilmiş ve veri artırma teknikleri (ölçeklendirme (rescaling), döndürme (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) ile artırılmış beyin MR görüntüleri veri setine uygulanmıştır. Modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

EfficientNetB3 modeli 43. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.17’de gösterilmiştir.



(a)



(b)

Şekil 4.17: EfficientNetB3 Ön Eğitimli Derin Öğrenme Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

EfficientNetB3 modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.5'te sunulmuştur.

Tablo 4.5: EfficientNetB3 Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri

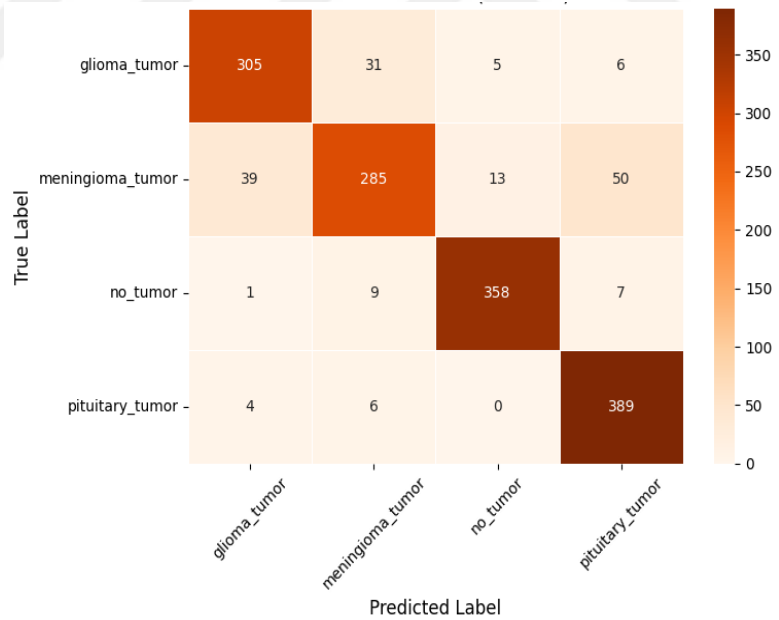
| EfficientNetB3 | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9005 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.8800 |
| Test Doğruluğu (Test Accuracy) | 0.8760 |

EfficientNetB3 modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.18’de sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.87 | 0.86 | 0.86 | 347 |
| meningioma_tumor | 0.84 | 0.73 | 0.78 | 387 |
| no_tumor | 0.95 | 0.94 | 0.94 | 375 |
| pituitary_tumor | 0.85 | 0.97 | 0.91 | 399 |
| accuracy | | | 0.88 | 1508 |
| macro avg | 0.88 | 0.88 | 0.87 | 1508 |
| weighted avg | 0.88 | 0.88 | 0.87 | 1508 |

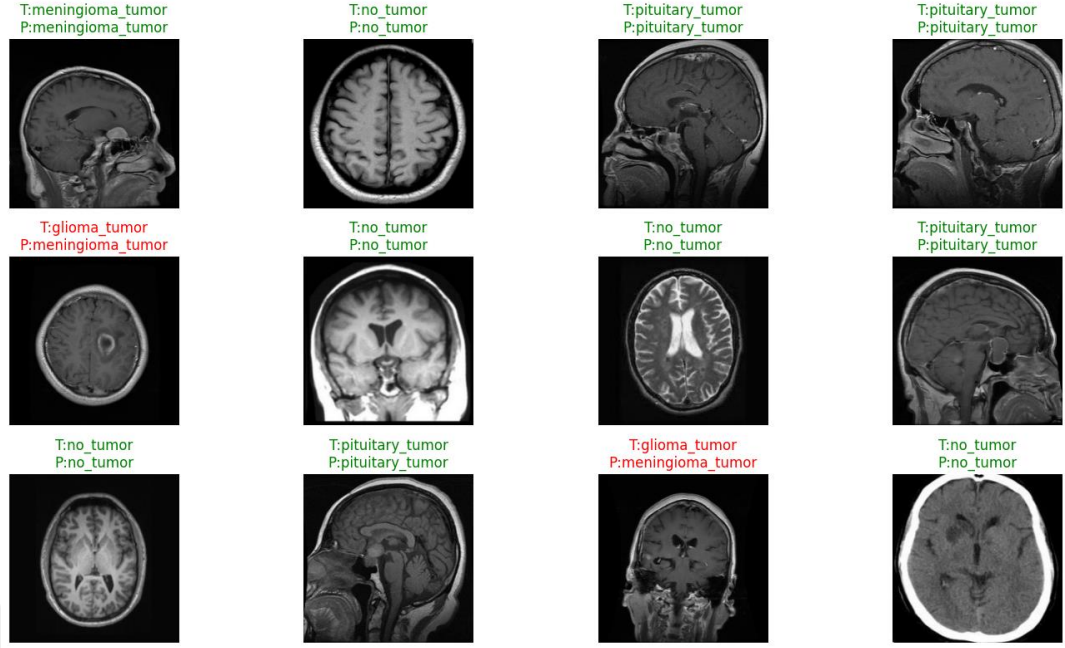
Şekil 4.18: EfficientNetB3 Modeline ait Sınıflandırma Raporu

EfficientNetB3 modeline ait karmaşıklık matrisi Şekil 4.19’da verilmiştir.



Şekil 4.19: EfficientNetB3 Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

EfficientNetB3 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.20’de verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir.



Şekil 4.20: EfficientNetB3 Modeline ait Beyin Tümörü Tahmin Görselleştirmesi

4.2. U-Net Segmentasyon İşlemi + Ön Eğitilmiş Derin Öğrenme Modelleri Deneysel Sonuçları


Bu bölümde tez çalışmasında uygulanan U-Net Segmentasyon İşlemi + Ön Eğitilmiş Derin Öğrenme Modellerinden oluşan hibrit modellerin (U-Net+ResNet50, U-Net+InceptionNetV3, U-Net+VGG19, U-Net+MobileNet ve U-Net+EfficientNetB3) test sonuçları raporlanmıştır. Hibrit modeller test edilirken artırılmamış veriyle ve artırılmış veriyle olmak üzere iki farklı başlık altında incelenmiştir. Bu sayede veri artırma işleminin U-Net segmentasyon işlemi ile maskelenmiş görüntüler üzerinde uygulanan ön eğitilmiş derin öğrenme yöntemlerinin sınıflandırma başarısına etkisi tespit edilmiştir.

Her hibrit modele ait test sonuçları için; eğitim turu (epoch) sayısı, kayıp (loss) değeri, doğruluk (accuracy) değeri, doğrulama kaybı (validation loss) değeri, doğrulama doğruluğu (validation accuracy) değerleri hesaplanmıştır. Ayrıca her modelin test sonucuna ait karmaşıklık matrisleri çizdirilmiş olup sınıflandırma değerlendirme ölçütleri (precision, recall, f1-score ve support) saptanmıştır.


4.2.1. U-Net + ResNet50 (Veri Artırmasız) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş ResNet50 ön eğitilmiş derin öğrenme modeli bu aşamada artırılmamış ham beyin MR görüntüleri veri seti üzerinde entegre modelin sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + ResNet50 modeli 23. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.21’de gösterilmiştir.



(a)



(b)

Şekil 4.21: U-Net + ResNet50 (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + ResNet50 entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.6’da sunulmuştur.

Tablo 4.6: U-Net + ResNet50 (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri

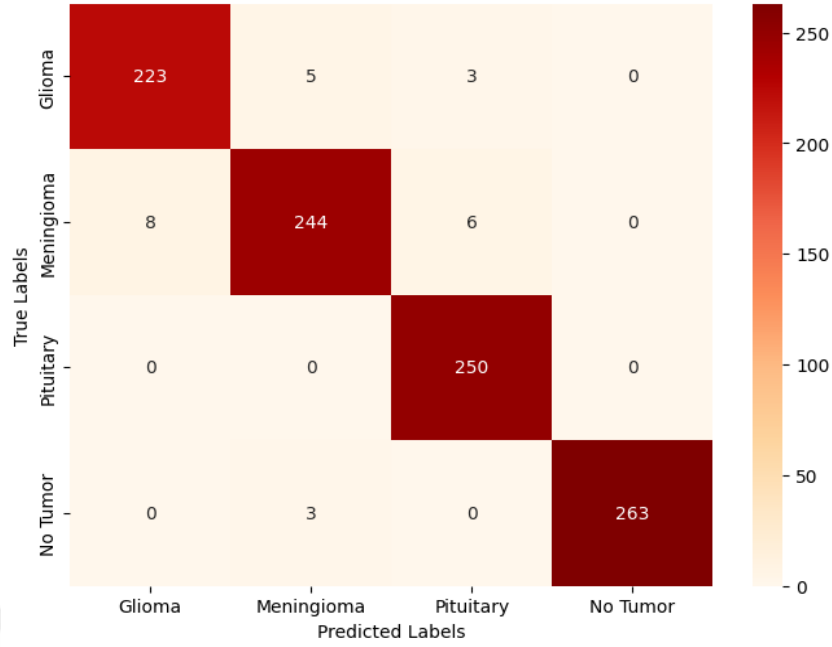
| U-Net + ResNet50 (Veri Artırmasız) | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9975 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9779 |
| Test Doğruluğu (Test Accuracy) | 0.9751 |

U-Net + ResNet50 entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporunda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.22’de sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.97 | 0.97 | 0.97 | 231 |
| meningioma_tumor | 0.97 | 0.95 | 0.96 | 258 |
| pituitary_tumor | 0.97 | 1.00 | 0.98 | 250 |
| no_tumor | 1.00 | 0.99 | 0.99 | 266 |
| accuracy | | | 0.98 | 1005 |
| macro avg | 0.97 | 0.97 | 0.97 | 1005 |
| weighted avg | 0.98 | 0.98 | 0.98 | 1005 |

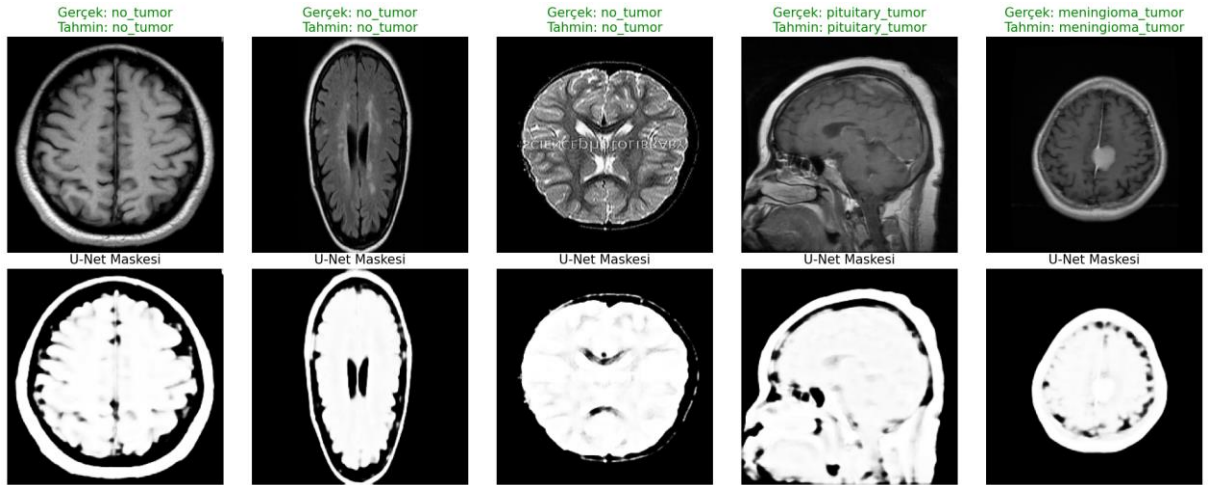
Şekil 4.22: U-Net + ResNet50 (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu

U-Net + ResNet50 (veri artırmasız) modeline ait karmaşıklık matrisi Şekil 4.23’te verilmiştir.



Şekil 4.23: U-Net + ResNet50 (Veri Artırmasız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + ResNet50 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.24'te verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.




Şekil 4.24: U-Net + ResNet50 (Veri Artırmasız) Modeline ait Beyin Tümörü Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)


4.2.2. U-Net + ResNet50 (Artırılmış Veri) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş ResNet50 ön eğitilmiş derin öğrenme modelinin bu aşamada veri artırma teknikleri (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) uygulanmış beyin MR görüntüleri üzerindeki sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + ResNet50 modeli 30. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.25'te gösterilmiştir.



(a)



(b)

Şekil 4.25: U-Net + ResNet50 (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + ResNet50 entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 8’de sunulmuştur.

Tablo 4.7: U-Net + ResNet50 (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| U-Net + ResNet50 (Artırılmış Veri) | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 1.0000 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9823 |
| Test Doğruluğu (Test Accuracy) | 0.9871 |

U-Net + ResNet50 entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.26'da sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 1.00 | 0.96 | 0.98 | 231 |
| meningioma_tumor | 0.96 | 1.00 | 0.98 | 258 |
| pituitary_tumor | 1.00 | 1.00 | 1.00 | 250 |
| no_tumor | 1.00 | 0.99 | 0.99 | 266 |
| accuracy | | | 0.99 | 1005 |
| macro avg | 0.99 | 0.99 | 0.99 | 1005 |
| weighted avg | 0.99 | 0.99 | 0.99 | 1005 |

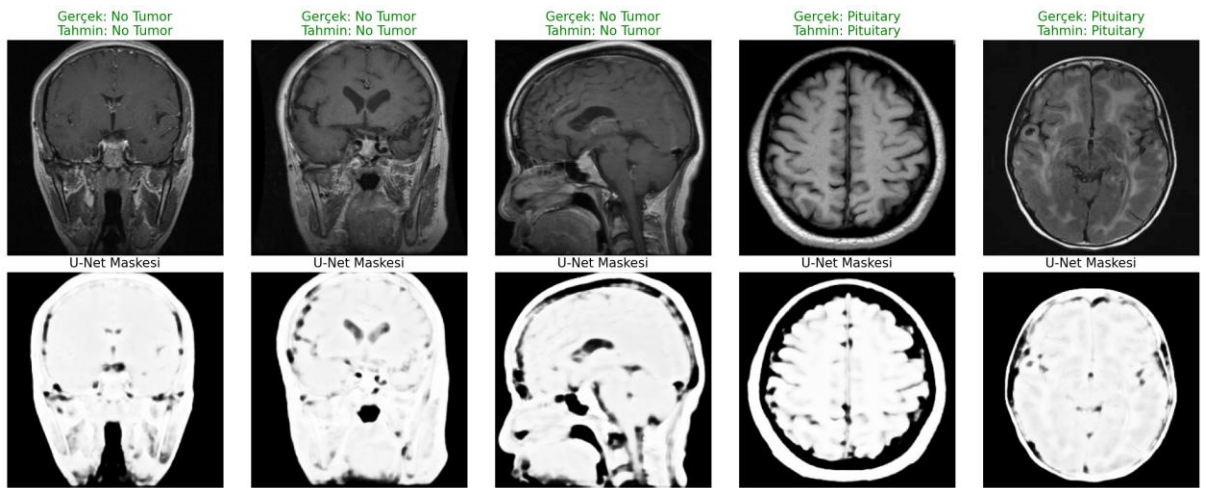
Şekil 4.26: U-Net + ResNet50 (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu

U-Net + ResNet50 (artırılmış veri) modeline ait karmaşıklık matrisi Şekil 4.27'de verilmiştir.



Şekil 4.27: U-Net + ResNet50 (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + ResNet50 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.28’de verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.

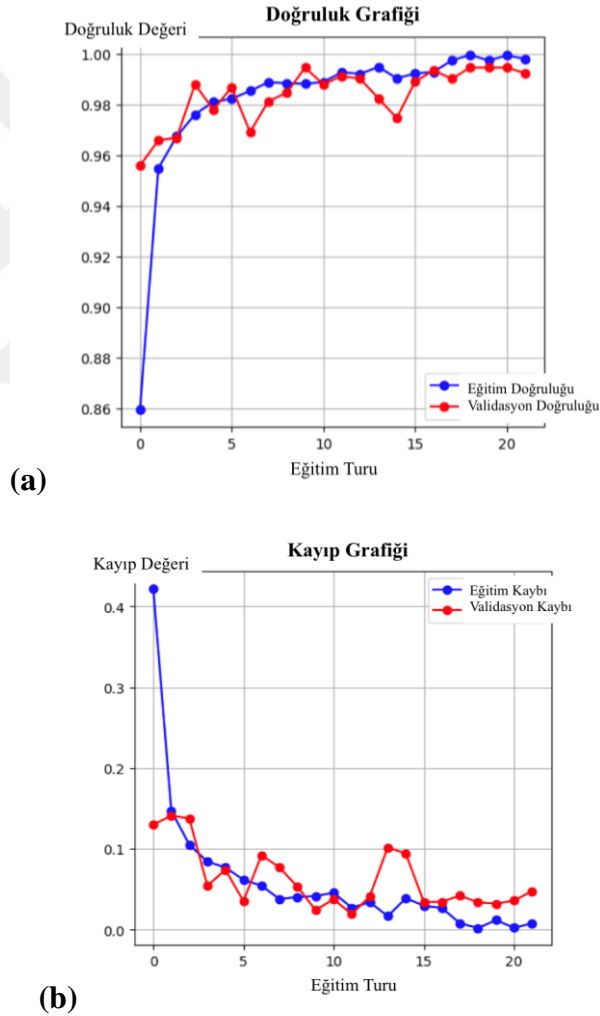


Şekil 4.28: U-Net + ResNet50 (Artırılmış Veri) Modeline ait Beyin Tümörü Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)

4.2.3. U-Net + InceptionNetV3 (Veri Artırmasız) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş InceptionNetV3 ön eğitilmiş derin öğrenme modeli bu aşamada artırılmamış ham beyin MR görüntüleri veri seti üzerinde entegre modelin sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + InceptionNetV3 modeli 22. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.29'da gösterilmiştir.



Şekil 4.29: U-Net + InceptionNetV3 (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + InceptionNetV3 entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.8’de sunulmuştur.

Tablo 4.8: U-Net + InceptionNetV3 (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| U-Net + InceptionNetV3 (Veri Artırmasız) | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9979 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9923 |
| Test Doğruluğu (Test Accuracy) | 0.9861 |

U-Net + InceptionNetV3 entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporla, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.30’da sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.97 | 0.97 | 0.97 | 231 |
| meningioma_tumor | 0.98 | 0.97 | 0.98 | 258 |
| pituitary_tumor | 0.99 | 0.99 | 0.99 | 250 |
| no_tumor | 0.98 | 0.99 | 0.99 | 266 |
| accuracy | | | 0.99 | 1005 |
| macro avg | 0.99 | 0.99 | 0.99 | 1005 |
| weighted avg | 0.99 | 0.99 | 0.99 | 1005 |


Şekil 4.30: U-Net + InceptionNetV3 (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu

U-Net + InceptionNetV3 (veri artırmasız) modeline ait karmaşıklık matrisi Şekil 4.31’de verilmiştir.



Şekil 4.31: U-Net + InceptionNetV3 (Veri Artırmazsız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + InceptionNetV3 modeli eğitimi sonucunda tahmin işlemi görselleştirilmesi Şekil 4.32’de verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.




Şekil 4.32: U-Net + InceptionNetV3 (Veri Artırmazsız) Modeline ait Beyin Tümör Tahmin Görselleştirilmesi (U-Net Tahmini Maskesi ile)


4.2.4. U-Net + InceptionNetV3 (Artırılmış Veri) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş InceptionNetV3 ön eğitimli derin öğrenme modelinin bu aşamada veri artırma teknikleri (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) uygulanmış beyin MR görüntüleri üzerindeki sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + InceptionNetV3 modeli 27. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.33'te gösterilmiştir.



(a)



(b)

Şekil 4.33: U-Net + InceptionNetV3 (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + InceptionNetV3 entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.9’da sunulmuştur.

Tablo 4.9: U-Net + InceptionNetV3 (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| U-Net + InceptionNetV3 (Artırılmış Veri) | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9995 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9934 |
| Test Doğruluğu (Test Accuracy) | 0.9891 |

U-Net + InceptionNetV3 entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.34'te sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.99 | 0.98 | 0.98 | 231 |
| meningioma_tumor | 0.98 | 0.98 | 0.98 | 258 |
| pituitary_tumor | 1.00 | 1.00 | 1.00 | 250 |
| no_tumor | 0.99 | 1.00 | 0.99 | 266 |
| accuracy | | | 0.99 | 1005 |
| macro avg | 0.99 | 0.99 | 0.99 | 1005 |
| weighted avg | 0.99 | 0.99 | 0.99 | 1005 |

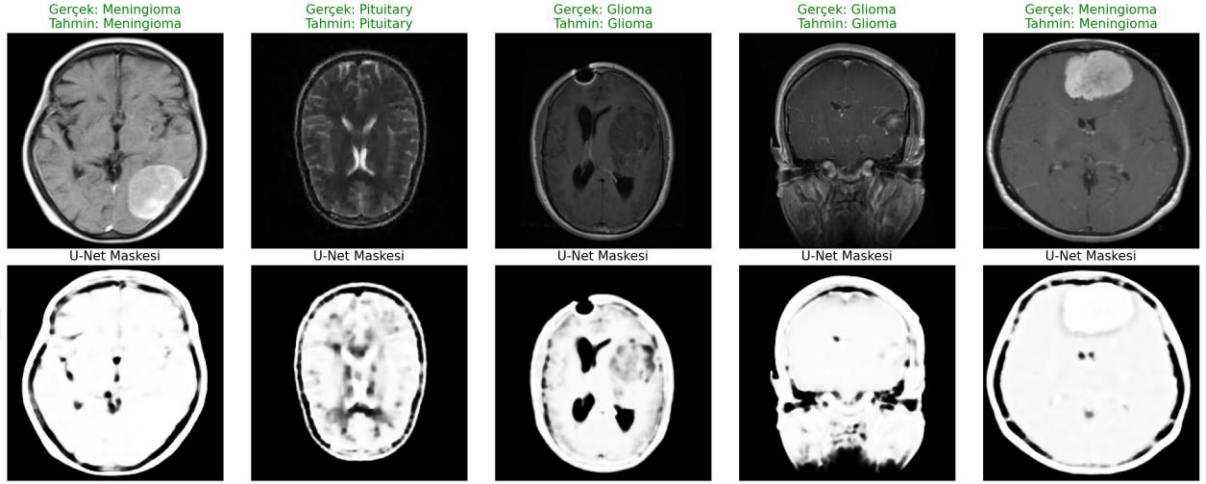
Şekil 4.34: U-Net + InceptionNetV3 (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu

U-Net + InceptionNetV3 (artırılmış veri) modeline ait karmaşıklık matrisi Şekil 4.35'te verilmiştir.



Şekil 4.35: U-Net + InceptionNetV3 (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + InceptionNetV3 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.36’da verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.




Şekil 4.36: U-Net + InceptionNetV3 (Artırılmış Veri) Modeline ait Beyin Tümörü Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)


4.2.5. U-Net + VGG19 (Veri Artırmasız) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş VGG19 ön eğitilmiş derin öğrenme modeli bu aşamada artırılmamış ham beyin MR görüntüleri veri seti üzerinde entegre modelin sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + VGG19 modeli 30. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.37’de gösterilmiştir.



(a)



(b)

Şekil 4.37: U-Net + VGG19 (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + VGG19 entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.10’da sunulmuştur.

Tablo 4.10: U-Net+VGG19 (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| U-Net + VGG19 (Veri Artırmasız) | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9948 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9702 |
| Test Doğruluğu (Test Accuracy) | 0.9891 |

U-Net + VGG19 entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.38’de sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.98 | 0.95 | 0.97 | 231 |
| meningioma_tumor | 0.96 | 0.97 | 0.97 | 258 |
| pituitary_tumor | 0.99 | 1.00 | 1.00 | 250 |
| no_tumor | 0.99 | 0.99 | 0.99 | 266 |
| accuracy | | | 0.98 | 1005 |
| macro avg | 0.98 | 0.98 | 0.98 | 1005 |
| weighted avg | 0.98 | 0.98 | 0.98 | 1005 |


Şekil 4.38: U-Net + VGG19 (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu

U-Net + VGG19 (veri artırmasız) modeline ait karmaşıklık matrisi Şekil 4.39’da verilmiştir.



Şekil 4.39: U-Net + VGG19 (Veri Artırmasız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + VGG19 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.40’da verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.




Şekil 4.40: U-Net + VGG19 (Veri Artırmasız) Modeline ait Beyin Tümörü Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)


4.2.6. U-Net + VGG19 (Artırılmış Veri) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş VGG19 ön eğitilmiş derin öğrenme modelinin bu aşamada veri artırma teknikleri (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) uygulanmış beyin MR görüntüleri üzerindeki sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + VGG19 modeli 34. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.41’de gösterilmiştir.



(a)



(b)

Şekil 4.41: U-Net + VGG19 (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + VGG19 entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.11’de sunulmuştur.

Tablo 4.11: U-Net+VGG19 (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| U-Net + VGG19 (Artırılmış Veri) | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9994 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9779 |
| Test Doğruluğu (Test Accuracy) | 0.9751 |

U-Net + VGG19 entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.42’de sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.96 | 0.95 | 0.95 | 231 |
| meningioma_tumor | 0.96 | 0.94 | 0.95 | 258 |
| pituitary_tumor | 0.96 | 1.00 | 0.98 | 250 |
| no_tumor | 0.99 | 0.98 | 0.98 | 266 |
| accuracy | | | 0.97 | 1005 |
| macro avg | 0.97 | 0.97 | 0.97 | 1005 |
| weighted avg | 0.97 | 0.97 | 0.97 | 1005 |

Şekil 4.42: U-Net + VGG19 (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu

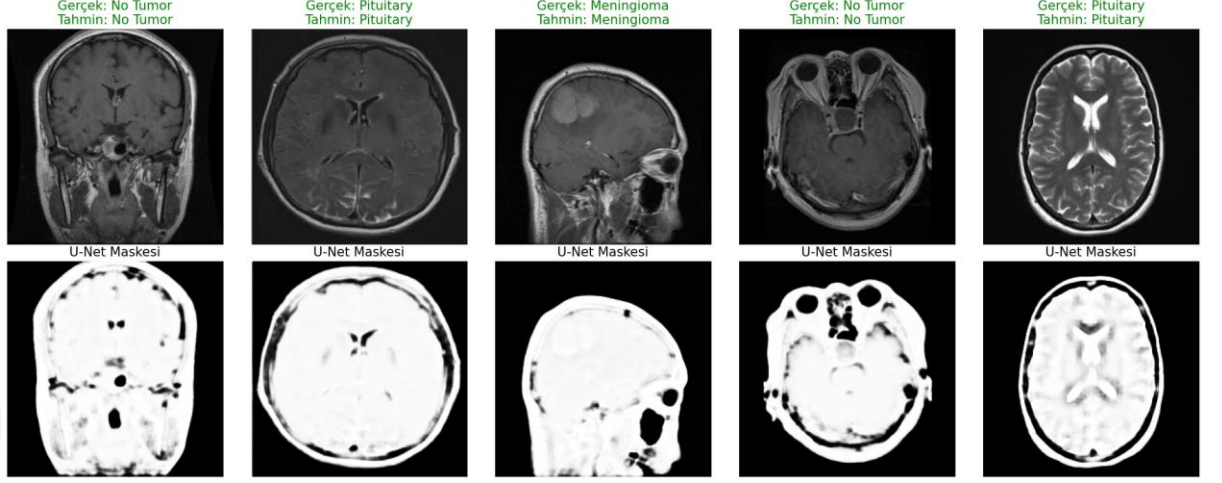
U-Net + VGG19 (artırılmış veri) modeline ait karmaşıklık matrisi Şekil 4.43’te verilmiştir.



Şekil 4.43: U-Net + VGG19 (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + VGG19 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.44’te verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf

bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.




Şekil 4.44: U-Net + VGG19 (Artırılmış Veri) Modeline ait Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)


4.2.7. U-Net + MobileNet (Veri Artırmasız) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş MobileNet ön eğitilmiş derin öğrenme modeli bu aşamada artırılmamış ham beyin MR görüntüleri veri seti üzerinde entegre modelin sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + MobileNet modeli 27. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.45'te gösterilmiştir.



(a)



(b)

Şekil 4.45: U-Net + MobileNet (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + MobileNet entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.12’de sunulmuştur.

Tablo 4.12: U-Net + MobileNet (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| U-Net + MobileNet (Veri Artırmasız) | Doğruluk Değeri (Accuracy) |
|---|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9983 |
| Doğrulama Doğruluğu (Validation Accuracy) | 0.9878 |
| Test Doğruluğu (Validation Accuracy) | 0.9831 |

U-Net + MobileNet entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.46’da sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 1.00 | 0.99 | 0.99 | 231 |
| meningioma_tumor | 1.00 | 0.99 | 0.99 | 258 |
| pituitary_tumor | 0.99 | 1.00 | 1.00 | 250 |
| no_tumor | 0.99 | 1.00 | 1.00 | 266 |
| accuracy | | | 1.00 | 1005 |
| macro avg | 1.00 | 0.99 | 0.99 | 1005 |

Şekil 4.46 U-Net + MobileNet (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu

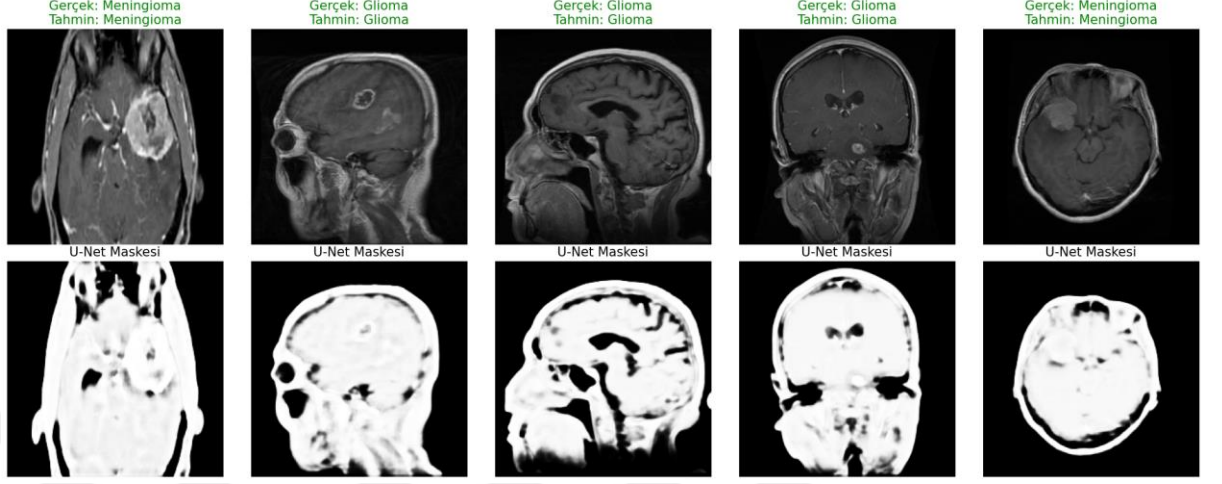
U-Net + MobileNet (veri artırmasız) modeline ait karmaşıklık matrisi Şekil 4.47’de verilmiştir.



Şekil 4.47: U-Net + MobileNet (Veri Artırmasız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + MobileNet modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.48’de verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf

bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.




Şekil 4.48: U-Net + MobileNet (Veri Artırmasız) Entegre Modeline ait Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)


4.2.8. U-Net + MobileNet (Artırılmış Veri) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş MobileNet ön eğitilmiş derin öğrenme modelinin bu aşamada veri artırma teknikleri (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) uygulanmış beyin MR görüntüleri üzerindeki sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + MobileNet modeli 26. eğitim turunda doğruluk değerinde değişim olmaması nedeniyle erken olarak durdurulmuştur. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.49’da gösterilmiştir.



(a)



(b)

Şekil 4.49: U-Net + MobileNet (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + MobileNet entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.13'te sunulmuştur.

Tablo 4.13: U-Net + MobileNet (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri

| U-Net + MobileNet (Artırılmış Veri) | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9999 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9890 |
| Test Doğruluğu (Test Accuracy) | 0.9911 |

U-Net + MobileNet entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporunda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.50’de sunulmuştur.

| | precision | recall | f1-score | support | |
|------------------|-----------|--------|----------|---------|------|
| glioma_tumor | 1.00 | 0.98 | 0.99 | 231 | |
| meningioma_tumor | 0.99 | 0.99 | 0.99 | 258 | |
| pituitary_tumor | 0.99 | 1.00 | 0.99 | 250 | |
| no_tumor | 0.99 | 1.00 | 0.99 | 266 | |
| accuracy | | | | 0.99 | 1005 |
| macro avg | 0.99 | 0.99 | 0.99 | 1005 | |
| weighted avg | 0.99 | 0.99 | 0.99 | 1005 | |

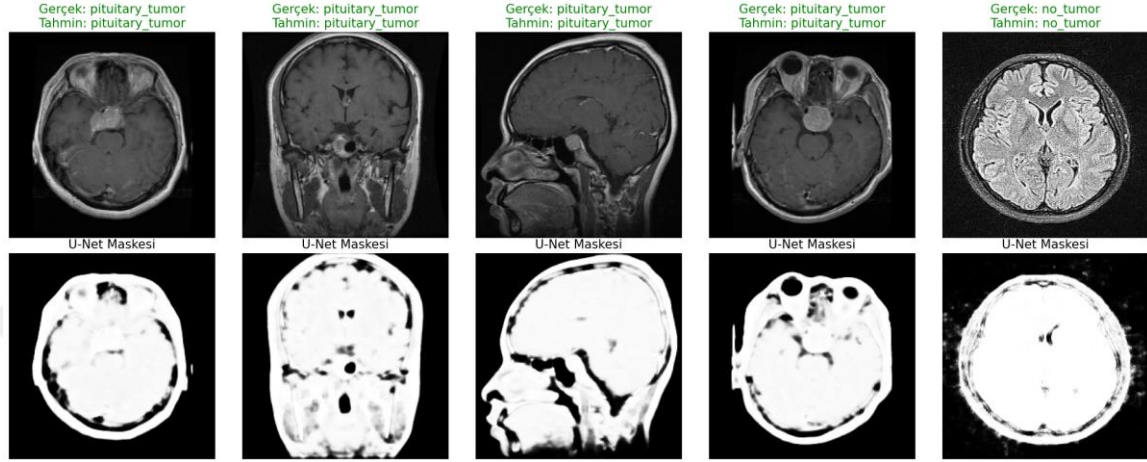
Şekil 4.50: U-Net + MobileNet (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu

U-Net + MobileNet (artırılmış veri) modeline ait karmaşıklık matrisi Şekil 4.51’de verilmiştir.



Şekil 4.51: U-Net + MobileNet (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + MobileNet modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.52’de verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.




Şekil 4.52: U-Net + MobileNet (Artırılmış Veri) Modeline ait Tahmin Görselleştirmesi (U-Net Tahmin Maskesi ile)


4.2.9. U-Net + EfficientNetB3 (Veri Artırmasız) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş EfficientNetB3 ön eğitilmiş derin öğrenme modeli bu aşamada artırılmamış ham beyin MR görüntüleri veri seti üzerinde entegre modelin sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + EfficientNetB3 modelinin eğitimi 100. eğitim turunda tamamlanmış olup erken olarak durdurulmamıştır. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.53’te gösterilmiştir.



(a)



(b)

Şekil 4.53: U-Net + EfficientNetB3 (Veri Artırmasız) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + EfficientNetB3 entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.14’te sunulmuştur.

Tablo 4.14: U-Net + EfficientNetB3 (Veri Artırmasız) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| U-Net + EfficientNetB3 (Veri Artırmasız) | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9475 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9288 |
| Test Doğruluğu (Test Accuracy) | 0.9572 |

U-Net + EfficientNetB3 entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.54'te sunulmuştur.

| | recision | recall | f1-score | support |
|------------------|----------|--------|----------|---------|
| glioma_tumor | 0.97 | 0.91 | 0.94 | 231 |
| meningioma_tumor | 0.91 | 0.93 | 0.92 | 258 |
| pituitary_tumor | 0.98 | 1.00 | 0.99 | 250 |
| no_tumor | 0.97 | 0.98 | 0.98 | 266 |
| accuracy | | | 0.96 | 1005 |
| macro avg | 0.96 | 0.96 | 0.96 | 1005 |

Şekil 4.54: U-Net + EfficientNetB3 (Veri Artırmasız) Entegre Modeline ait Sınıflandırma Raporu

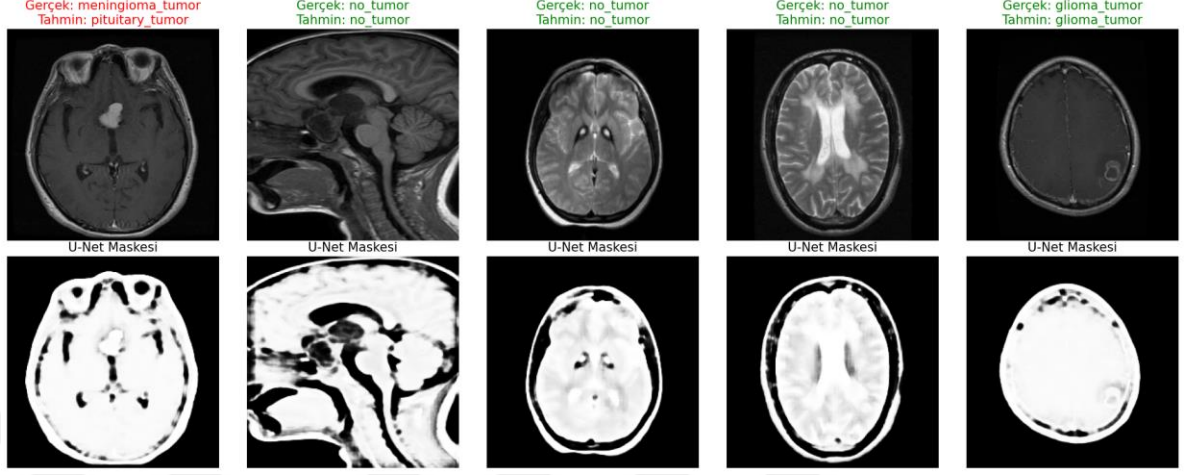
U-Net + EfficientNetB3 (veri artırmasız) modeline ait karmaşıklık matrisi Şekil 4.55'te verilmiştir.



Şekil 4.55: U-Net + EfficientNetB3 (Veri Artırmasız) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + EfficientNetB3 modeli eğitimi sonucunda tahmin işlemi görselleştirilmesi Şekil 4.56'da verilmiştir. "P": tahmin ettiği sınıf bilgisini, "T" görüntünün gerçek sınıf

bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.




Şekil 4.56: U-Net + EfficientNetB3 (Veri Artırmasız) Entegre Modeline ait Eğitim/Doğrulama Doğruluğu ve Eğitim/Doğrulama Kaybı Grafikleri


4.2.10. U-Net + EfficientNetB3 (Artırılmış Veri) Modeli Deneysel Sonuçları

U-Net segmentasyonu ile entegre edilmiş EfficientNet ön eğitilmiş derin öğrenme modelinin bu aşamada veri artırma teknikleri (rotation), yatay çevirme (horizontal flip), paralel kaydırma (shearing), parlaklık (brightness)) uygulanmış beyin MR görüntüleri üzerindeki sınıflandırma performansı test edilmiştir. Entegre modelin sınıflandırma performansı test edilirken eğitim turu (epoch) sayısının başlangıç değeri 100 olarak belirlenmiş olup erken durdurma (early stopping) fonksiyonu tanımlanmıştır.

U-Net + EfficientNetB3 modelinin eğitimi 150. eğitim turunda tamamlanmış olup erken olarak durdurulmamıştır. Modele ait eğitim/doğrulama doğruluğu ve eğitim/doğrulama kaybı grafikleri Şekil 4.57’de gösterilmiştir.



(a)



(b)

Şekil 4.57: U-Net + EfficientNetB3 (Artırılmış Veri) Entegre Modeline ait (a) Eğitim/Doğrulama Doğruluğu ve (b) Eğitim/Doğrulama Kaybı Grafikleri

U-Net + EfficientNetB3 entegre modeline ait eğitim, doğrulama ve test doğruluğu değerleri Tablo 4.15’te sunulmuştur.

Tablo 4.15: U-Net + EfficientNetB3 (Artırılmış Veri) Modelinin Eğitim, Doğrulama ve Test Doğruluğu Değerleri


| U-Net + EfficientNetB3 (Artırılmış Veri) | Doğruluk Değeri (Accuracy) |
|--|----------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.7248 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9403 |
| Test Doğruluğu (Test Accuracy) | 0.9373 |

U-Net + EfficientNetB3 entegre modelinin sınıflandırma başarısını değerlendirmek için sınıflandırma raporu oluşturulmuştur. Raporda, her sınıfa ait precision, recall ve F1-score değerleri bulunmaktadır. Modele ait sınıflandırma raporu Şekil 4.58’de sunulmuştur.

| | precision | recall | f1-score | support |
|------------------|-----------|--------|----------|---------|
| glioma_tumor | 0.95 | 0.90 | 0.92 | 231 |
| meningioma_tumor | 0.88 | 0.91 | 0.89 | 258 |
| pituitary_tumor | 0.96 | 0.97 | 0.97 | 250 |
| no_tumor | 0.97 | 0.97 | 0.97 | 266 |
| accuracy | | | 0.94 | 1005 |
| macro avg | 0.94 | 0.94 | 0.94 | 1005 |
| weighted avg | 0.94 | 0.94 | 0.94 | 1005 |

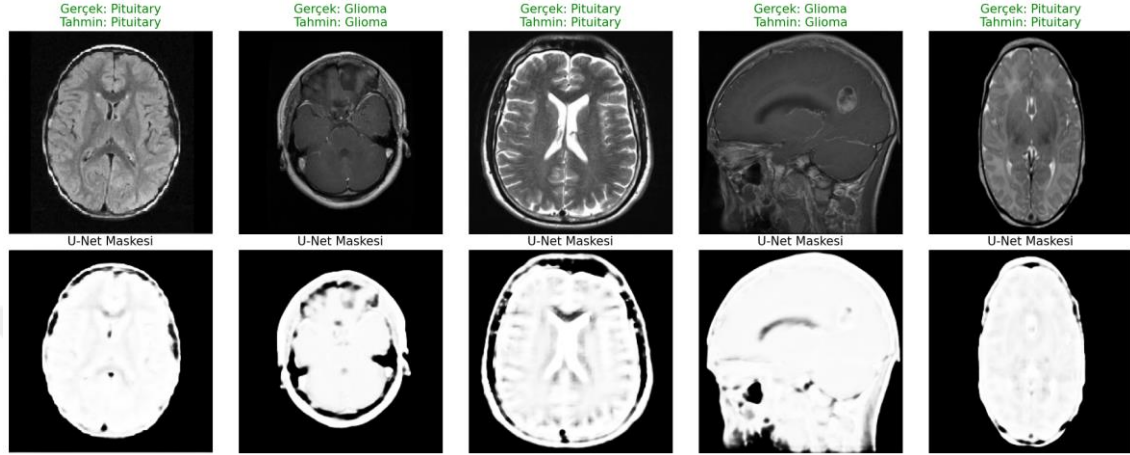
Şekil 4.58: U-Net + EfficientNetB3 (Artırılmış Veri) Entegre Modeline ait Sınıflandırma Raporu

U-Net + EfficientNetB3 (artırılmış veri) modeline ait karmaşıklık matrisi Şekil 4.59’da verilmiştir.



Şekil 4.59: U-Net + EfficientNetB3 (Artırılmış Veri) Entegre Modeline ait Karmaşıklık Matrisi (Confusion Matrix)

U-Net + EfficientNetB3 modeli eğitimi sonucunda tahmin işlemi görselleştirmesi Şekil 4.60’da verilmiştir. “P”: tahmin ettiği sınıf bilgisini, “T” görüntünün gerçek sınıf bilgisini göstermekte olup yeşil renkli yazılan tahmin işleminin doğru işlem olduğunu, kırmızı renkli yazılan tahmin işleminin yanlış olduğunu ifade etmektedir. Ayrıca tahmin görselinin altında tahmin edilen sınıfın U-Net maskesi de gösterilmiştir.



Şekil 4.60: U-Net+EfficientNetB3 (Artırılmış Veri) Modeline ait Tahmin Görselleştirmesi (U-Net Tahmini Maskesi ile)

4.3. Transfer Öğrenme Modelleri ile U-Net Tabanlı Transfer Öğrenme Modellerinin Karşılaştırılması

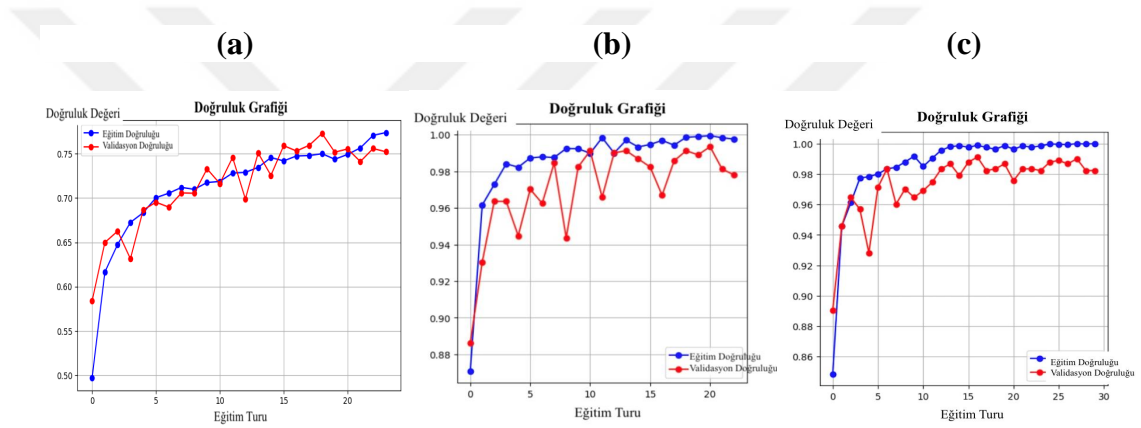
Bu bölümde ön eğitilmiş derin öğrenme (transfer learning) modellerinden ve U-Net tabanlı ön eğitilmiş derin öğrenme modellerinden elde edilen doğruluk değerlerinin karşılaştırmalı analiz tabloları ve grafikleri bulunmaktadır. Tablolar ve grafikler tüm ön eğitilmiş derin öğrenme (transfer öğrenme) modelleri için ayrı olarak hazırlanmıştır.

ResNet50 ve U-Net Tabanlı ResNet50 modellerine ait doğruluk değerlerinin karşılaştırması Tablo 4.16’da verilmiştir.

Tablo 4.16: ResNet50 ve U-Net Tabanlı ResNet50 Modellerine ait Doğruluk Değerleri Karşılaştırması

| Doğruluk Değerleri/Modeller | ResNet50 (Artırılmış Veri) | U-Net + ResNet50 (Veri Artırmaz) | U-Net + ResNet50 (Artırılmış Veri) |
|--|----------------------------|----------------------------------|------------------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.7738 | 0.9975 | 1.0000 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.7522 | 0.9779 | 0.9823 |
| Test Doğruluğu (Test Accuracy) | 0.7773 | 0.9751 | 0.9871 |

ResNet50 ve U-Net Tabanlı ResNet50 modellerine ait doğruluk grafiklerinin karşılaştırılması Şekil 4.61’de verilmiştir.




Şekil 4.61: ResNet50 ve U-Net Tabanlı ResNet50 Modellerinin Doğruluk Grafikleri (a) ResNet50 Modeli (b) Veri Artırmaz U-Net + ResNet50 Modeli (c) Artırılmış Veri ile U-Net + ResNet50 Modeli

InceptionNetV3 ve U-Net Tabanlı InceptionNetV3 modellerine ait doğruluk değerlerinin karşılaştırması Tablo 4.17’de verilmiştir.

Tablo 4.17: InceptionNetV3 ve U-Net Tabanlı InceptionNetV3 Modellerinin Doğruluk Değerleri Karşılaştırması

| Doğruluk Değerleri/Modeller | InceptionNetV3 (Artırılmış Veri) | U-Net+InceptionNetV3 (Veri Artırmaz) | U-Net+InceptionNetV3 (Artırılmış Veri) |
|--|----------------------------------|--------------------------------------|--|
| Eğitim Doğruluğu (Train Accuracy) | 0.9989 | 0.9979 | 0.9995 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9854 | 0.9923 | 0.9934 |
| Test Doğruluğu (Test Accuracy) | 0.9907 | 0.9861 | 0.9891 |

InceptionNetV3 ve U-Net Tabanlı InceptionNetV3 modellerine ait doğruluk grafiklerinin karşılaştırılması Şekil 4.62’de verilmiştir.



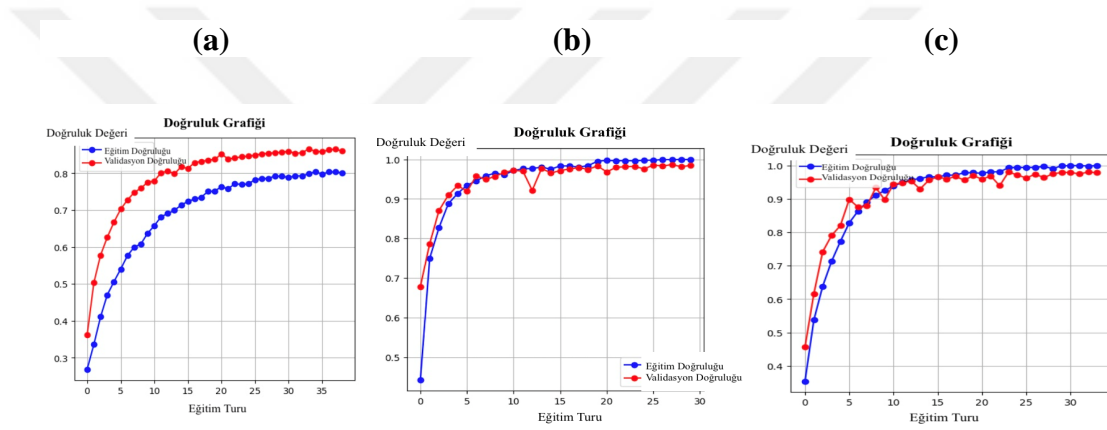
Şekil 4.62: InceptionNetV3 ve U-Net Tabanlı InceptionNetV3 Modellerinin Doğruluk Grafikleri (a) InceptionNetV3 Modeli (b) Veri Artırmaz U-Net + InceptionNetV3 Modeli (c) Artırılmış Veri ile U-Net + InceptionNetV3 Modeli

VGG19 ve U-Net Tabanlı VGG19 modellerine ait doğruluk değerlerinin karşılaştırması Tablo 4.18’de verilmiştir.

Tablo 4.18: VGG19 ve U-Net Tabanlı VGG19 Modellerinin Doğruluk Değerleri Karşılaştırması

| Doğruluk Değerleri/Modeller | VGG19 (Artırılmış Veri) | U-Net+VGG19 (Veri Artırmaz) | U-Net+VGG19 (Artırılmış Veri) |
|--|-------------------------|-----------------------------|-------------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.8890 | 0.9948 | 0.9994 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.8739 | 0.9702 | 0.9779 |
| Test Doğruluğu (Test Accuracy) | 0.8660 | 0.9891 | 0.9751 |

VGG19 ve U-Net Tabanlı VGG19 modellerine ait doğruluk grafiklerinin karşılaştırılması Şekil 4.63'te verilmiştir.



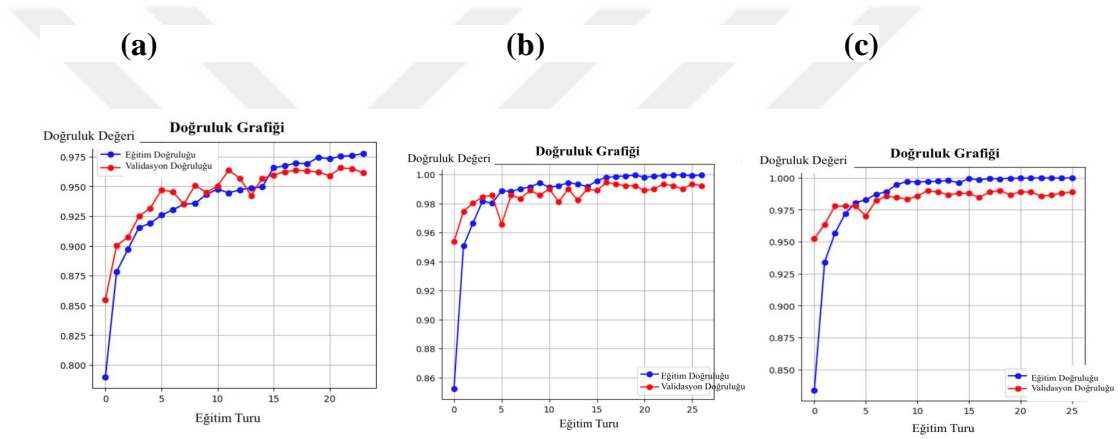
Şekil 4.63: VGG19 ve U-Net Tabanlı VGG19 Modellerinin Doğruluk Grafikleri (a) VGG19 Modeli (b) Veri Artırmaz U-Net + VGG19 Modeli (c) Artırılmış Veri ile U-Net + VGG19 Modeli

MobileNet ve U-Net Tabanlı MobileNet modellerine ait doğruluk değerlerinin karşılaştırması Tablo 4.19'da verilmiştir.

Tablo 4.19: MobileNet ve U-Net Tabanlı MobileNet Modellerinin Doğruluk Değerleri Karşılaştırması

| Doğruluk Değerleri/Modeller | MobileNet (Artırılmış Veri) | U-Net + MobileNet (Veri Artırmaz) | U-Net + MobileNet (Artırılmış Veri) |
|--|-----------------------------|-----------------------------------|-------------------------------------|
| Eğitim Doğruluğu (Train Accuracy) | 0.9831 | 0.9983 | 0.9999 |
| Validasyon Doğruluğu (Validation Accuracy) | 0.9628 | 0.9878 | 0.9890 |
| Test Doğruluğu (Test Accuracy) | 0.9662 | 0.9831 | 0.9911 |

MobileNet ve U-Net Tabanlı MobileNet modellerine ait doğruluk grafiklerinin karşılaştırılması Şekil 4.64'te verilmiştir.



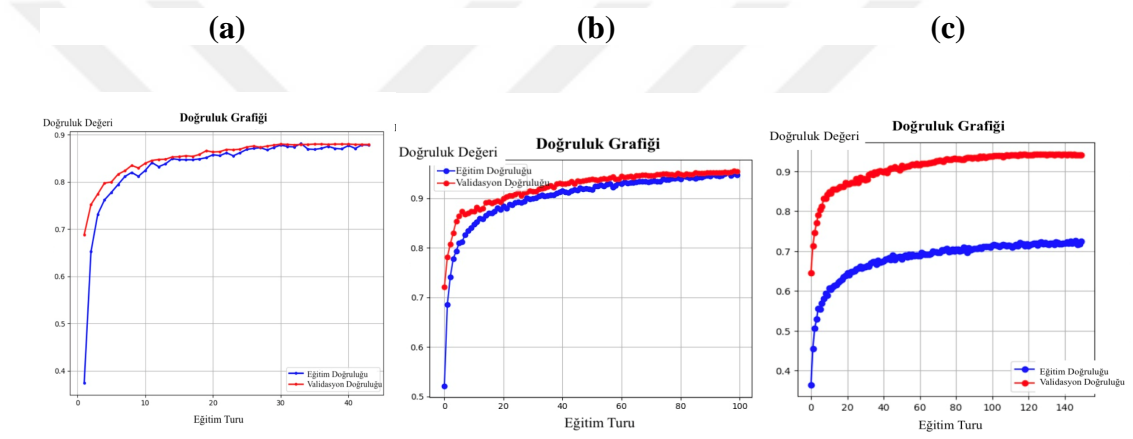
Şekil 4.64: MobileNet ve U-Net Tabanlı MobileNet Modellerinin Doğruluk Grafikleri (a) MobileNet Modeli (b) Veri Artırmaz U-Net + MobileNet Modeli (c) Artırılmış Veri ile U-Net + MobileNet Modeli

EfficientNetB3 ve U-Net Tabanlı EfficientNetB3 modellerine ait doğruluk değerlerinin karşılaştırması Tablo 4.20'de verilmiştir.

Tablo 4.20: EfficientNetB3 ve U-Net Tabanlı EfficientNetB3 Modellerinin Doğruluk Değerleri Karşılaştırması

| Doğruluk Değerleri/Modeller | EfficientNetB3 (Artırılmış Veri) | U-Net+EfficientNetB3 (Veri Artırmaz) | U-Net+EfficientNetB3 (Artırılmış Veri) |
|---|----------------------------------|--------------------------------------|--|
| Eğitim Doğruluğu (Train Accuracy) | 0.9005 | 0.9475 | 0.7248 |
| Doğrulama Doğruluğu (Validation Accuracy) | 0.8800 | 0.9288 | 0.9403 |
| Test Doğruluğu (Test Accuracy) | 0.8760 | 0.9572 | 0.9373 |

EfficientNetB3 ve U-Net Tabanlı EfficientNetB3 modellerine ait doğruluk grafiklerinin karşılaştırılması Şekil 4.65’te verilmiştir.



Şekil 4.65: EfficientNetB3 ve U-Net Tabanlı EfficientNetB3 Modellerinin Doğruluk Grafikleri (a) EfficientNetB3 Modeli (b) Veri Artırmaz U-Net + EfficientNetB3 Modeli (c) Artırılmış Veri ile U-Net + EfficientNetB3 Modeli

SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, maskeleyme işlemi uygulanmış manyetik rezonans (MR) görüntülerinden beyin tümörlerinin dört farklı kategoriye (glioma, meningioma, hipofiz tümörü ve tümör içermeyen) ayrılmasına yönelik bir sınıflandırma süreci gerçekleştirilmiştir. Bu amaç doğrultusunda, önceden eğitilmiş çeşitli transfer öğrenme modelleri (ResNet50, InceptionNetV3, VGG19, MobileNet ve EfficientNetB3) kullanılarak kapsamlı deneysel analizler yapılmıştır. Ayrıca çalışmada, U-Net mimarisinden faydalanılarak gerçekleştirilen segmentasyonun sınıflandırma performansı üzerindeki etkileri değerlendirilmiş ve böylelikle hibrit bir yaklaşım önerilmiştir. Özellikle veri çeşitliliğini artırma stratejileri ile segmentasyon temelli sınıflandırma performanslarının karşılaştırılması hedeflenmiş; elde edilen bulgular bu amacın başarıyla gerçekleştirildiğini ortaya koymuştur.

Çalışma kapsamında deneyler, üç ana modelleme yöntemi etrafında şekillendirilmiştir: Bu yöntemler aşağıdaki gibi listelenebilir:

- Veri artırma tekniklerinin uygulandığı klasik transfer öğrenme tabanlı modeller,
- U-Net ile maskeleyme işlemi sonrası segmentasyon uygulanmış, ancak veri artırma gerçekleştirilmemiş hibrit modeller,
- Hem segmentasyon (U-Net) hem de veri artırma yöntemlerinin birlikte kullanıldığı hibrit modelledir.

Önerilen modellerden elde edilen doğruluk değerleri değerlendirildiğinde, tüm transfer öğrenme mimarilerinde U-Net segmentasyonu ile maskeleyme yapılmasının sınıflandırma başarımını belirgin şekilde artırdığı görülmüştür. Özellikle segmentasyon işlemiyle birlikte veri artırma uygulamalarının entegre edilmesi, çoğu modelde test doğruluklarının en yüksek seviyelere ulaşmasını sağlamıştır. Bu durum, hibrit yaklaşımın modellerin performansları üzerindeki etkilerinin olumlu olduğunu açıkça göstermiştir.

ResNet50 mimarisi, veri artırma yöntemleriyle zenginleştirilmiş görüntülerle eğitildiğinde sırasıyla %77,38 eğitim doğruluğu, %75,22 doğrulama doğruluğu ve %77,73 test doğruluğu saptanmıştır. Bu sonuçlar, ResNet50'nin derin yapısının sınıflandırma görevinde kayda değer bir başarı sağladığını, ancak doğruluk değerlerinin yükseltilmesi için ek model iyileştirmelerine ihtiyaç duyulduğunu

göstermektedir. Aynı mimari, U-Net segmentasyon yöntemiyle işlenmiş görüntüler kullanılarak ve veri artırma yapılmaksızın eğitildiğinde, eğitimde %99,75, doğrulamada %97,79 ve testte %97,51 doğruluk oranlarına ulaşmıştır. Bu ciddi artış, segmentasyonun sınıflandırma başarımına oldukça önemli bir katkısının olduğunu göstermektedir. Maskeleye işleme veri artırma tekniklerinin de eklenmesiyle geliştirilen U-Net + ResNet50 modeli ise %100 eğitim doğruluğu, %98,23 doğrulama doğruluğu ve %98,71 test doğruluğu ile başarılı bir sınıflandırma performansı sergilemiştir. Bu bulgulara göre, ResNet50'nin segmentasyon ve veri artırma ile birlikte oldukça güçlü bir sınıflandırma kabiliyeti sunduğu açıkça gösterilmektedir.

InceptionNetV3 modeli, veri artırma teknikleriyle genişletilen eğitim setiyle %99,89 eğitim doğruluğu, %98,54 doğrulama doğruluğu ve %99,07 test doğruluğu elde etmiştir. Bu oranlar, modelin yüksek doğruluk sağlamanın ötesinde aynı zamanda güçlü bir genelleme yeteneği sunduğunu da göstermektedir. U-Net segmentasyonu ile maskelenmiş ve veri artırılmamış veri setiyle eğitilen versiyonu olan U-Net + InceptionNetV3 modeli ise sırasıyla %99,79, %99,23 ve %98,61 doğruluk değerleriyle dikkate değer bir başarı sergilemiştir. Segmentasyonun modelin performansını güçlendirdiği bu sonuçlarla açık bir şekilde gösterilmiştir. Bu iki yöntemin birlikte uygulandığı hibrit yapı ise, eğitim doğruluğunda %99,95, doğrulama doğruluğunda %99,34 ve test doğruluğunda %98,91 gibi oldukça dengeli ve yüksek doğruluk seviyeleriyle öne çıkmıştır. InceptionNetV3 tabanlı yapılar, genel değerlendirme açısından en yüksek doğruluklara ulaşarak sınıflandırma görevinde en başarılı mimariler arasında yerini almıştır.

Klasik bir yapıya sahip olan VGG19 mimarisi, veri artırma teknikleriyle eğitildiğinde sırasıyla %88,90 eğitim doğruluğu, %87,39 doğrulama doğruluğu ve %86,60 test doğruluğu sağlamıştır. Bu doğruluk oranları, modelin derin yapısının bazı durumlarda aşırı öğrenmeye (overfitting) yatkın olduğunu düşündürmektedir. Segmentasyon işlemi sonrasında ve veri artırma yapılmadan eğitilen U-Net+VGG19 modeli ise %99,48 eğitim doğruluğu, %97,02 doğrulama doğruluğu ve %98,91 test doğruluğuna ulaşmıştır. Segmentasyonun özellikle test verileri üzerinde performansı ciddi şekilde artırdığı bu sonuçlarla kanıtlanmıştır. Maskeleye ile birlikte veri artırma da uygulandığında, modelin %99,94 eğitim doğruluğu, %97,79 doğrulama doğruluğu ve %97,51 test doğruluğu sunduğu görülmüştür. Her ne kadar bu değerler oldukça yüksek

olsa da, test doğruluğundaki sınırlı artış, modelin bazı sınıflar arasında ayırım yapmada zorluk yaşadığını gösterebilir.

Hafif yapıli bir model olan MobileNet, artırılmış verilerle eğitildiğinde sırasıyla %98,31 eğitim doğruluğu, %96,28 doğrulama doğruluğu ve %96,62 test doğruluğu elde etmiştir. Bu yüksek başarı, modelin düşük parametre sayısına rağmen etkili bir sınıflandırma performansı sunduğunu ortaya koymaktadır. U-Net ile maskelenmiş ve veri artırma yapılmaksızın eğitilen U-Net+MobileNet modeli ise %99,83 eğitim doğruluğu, %98,78 doğrulama doğruluğu ve %98,31 test doğruluğu ile kayda değer bir artış göstermiştir. Segmentasyonun model başarımına olan olumlu etkisi açıkça gözlenmektedir. Hibrit yapıya veri artırma da eklendiğinde, eğitim doğruluğu %99,99, doğrulama doğruluğu %98,90 ve test doğruluğu %99,11'e ulaşmış ve bu yapı, hem verimlilik hem de doğruluk açısından oldukça başarılı bir örnek olarak öne çıkmıştır.

EfficientNetB3 mimarisi, artırılmış verilerle eğitildiğinde sırasıyla %90,05 eğitim doğruluğu, %88,00 doğrulama doğruluğu ve %87,60 test doğruluğu elde edilmiştir. Bu sonuçlara göre, model temel formuyla başarılı bir performans sergilemiş, fakat diğer modeller arasında daha sınırlı kaldığını göstermektedir. Segmentasyon sonrası veri artırma yapılmadan eğitilen U-Net+EfficientNetB3 modeli, %94,75 eğitim doğruluğu, %92,88 doğrulama doğruluğu ve %95,72 test doğruluğu ile dikkate değer bir gelişme sunmuştur. Maskalemenin performansa olan katkısı burada da gözlemlenmektedir. Ancak hem segmentasyon hem de veri artırma birlikte uygulandığında, eğitim doğruluğu beklenenden düşük bir değer olan %72,48'de kalırken, doğrulama ve test doğrulukları sırasıyla %94,03 ve %93,73 olarak elde edilmiş olup bu duruma göre, modelin eğitim verisine yeterince adapte olamadığını ya da segmentasyon işlemi sonrası verilerin öğrenme sürecini farklı şekillerde etkilediği düşünülmektedir. Diğer yandan test doğruluğunun yüksekliği, modelin genelleme kapasitesinin kuvvetli olduğunu göstermektedir.

Bu tez çalışması, beyin tümörlerinin sınıflandırılmasına yönelik literatürdeki mevcut yaklaşımların ötesine geçerek, hem veri ön işleme süreçlerine hem de modelleme stratejilerine çok katmanlı katkılar sunmaktadır. Özellikle farklı açık kaynaklı veri kümelerinin bir araya getirilmesiyle oluşturulan geniş ve dengeli veri seti, daha güvenilir ve genellenebilir bir sınıflandırma altyapısının geliştirilmesine imkân tanımıştır. Literatürde çoğunlukla tek kaynaklı veriler üzerinden yürütülen

sınıflandırma çalışmaları göz önüne alındığında, bu tezde birden fazla veri setinin entegre edilmesi; sınıflar arası dengenin sağlanmasına ve modelin öğrenme kapasitesinin yükseltilmesine olanak tanınması açısından önemli bir yenilik olarak değerlendirilmektedir.

Çalışmanın öne çıkan katkılarından biri, segmentasyon ve sınıflandırma işlemlerinin birlikte ele alınarak entegre bir yapıda analiz edilmiş olmasıdır. U-Net mimarisıyla gerçekleştirilen segmentasyon işlemi sayesinde, görüntülerin yalnızca tümörle ilişkili bölgelerine odaklanılmış ve bu yaklaşım, sınıflandırma performansında belirgin iyileşmeler sağlamıştır. Segmentasyon uygulaması, yalnızca ilgisiz alanların etkisizleştirilmesi açısından değil, aynı zamanda modelin dikkatini doğru alanlara yönlendirmesi bakımından da etkili olmuş ve sınıflandırma doğruluklarını anlamlı şekilde artırmıştır. Bu yönüyle tez, ön işleme süreçlerini iyileştiren ve sınıflandırma kalitesini yükselten bütüncül bir metodoloji sunmaktadır.

Ayrıca çalışmada, farklı mimari özelliklere sahip beş ayrı ön-egitimli derin öğrenme modelinin hem klasik formlarıyla hem de U-Net ile bütünleştirilmiş hibrit yapıdaki versiyonlarıyla sistematik karşılaştırmaları gerçekleştirilmiştir. Sadece en yüksek başarıyı sağlayan mimari değil, her modelin çeşitli senaryolardaki davranış biçimleri ayrıntılı bir biçimde analizi yapılarak, zayıf ve güçlü olan yönleri ayrı ayrı değerlendirilmiştir. Bu kapsamlı analiz yaklaşımı, benzer alanda çalışacak araştırmacılar için yalnızca bir teknik referans değil, aynı zamanda metodolojik bir kılavuz niteliği taşımaktadır.

Çalışmanın dikkat çekici olan bir diğer yönü ise veri artırma yöntemlerinin hem ham veri üzerinde hem de segmentasyon sonrası oluşturulan veri üzerinde uygulanarak sınıflandırma üzerindeki etkilerinin çift yönlü olarak test edilmesidir. Bu sayede, veri artırma tekniklerinin yalnızca model performansına değil, ön işleme süreciyle olan etkileşimine dair de derinlemesine içgörüler elde edilmiştir. Sonuç olarak bu tez çalışması, transfer öğrenme, veri artırma ve görüntü maskeleyme tekniklerini bir araya getirerek özgün ve çok boyutlu bir araştırma çerçevesi sunmaktadır.

Elde edilen bulgulara göre, gelecekte çalışmalar adına çeşitli geliştirme önerileri sunulabilir. Her ne kadar oluşturulan veri seti birden fazla açık kaynaklı kaynaktan birleştirilmiş olsa da, farklı hastanelerden ya da çeşitli manyetik rezonans (MR) cihazlarından alınacak görüntülerle veri çeşitliliğinin artırılması, geliştirilen

modellerin gerçek dünya koşullarındaki genellenebilirliğini daha sağlam bir biçimde değerlendirmeye olanak sağlayacaktır. Böylece, klinik uygulamalarda model performanslarının geçerliliği daha net ortaya konabilecektir.

Segmentasyon işlemleri için tercih edilen U-Net mimarisi, temel bir başarı sağlamış olsada, U-Net++ veya Attention U-Net gibi daha gelişmiş segmentasyon mimarilerinin kullanılması, maskeleye hassasiyetini artırarak sınıflandırma başarılarını daha ileri seviyelere taşıyabilir. Bunun yanında, sadece tek modaliteli MR görüntüleri yerine T1, T2 veya FLAIR gibi farklı modaliteleri bir araya getiren çoklu modalite yaklaşımı, özellikle glioma gibi sınıflandırılması güç tümör türlerinin ayırt edilmesini kolaylaştırabilir.

Uygulanan transfer öğrenme yöntemleri, sınırlı veri koşullarında dahi yüksek doğruluklar sunabilmiştir. Ancak bu modellerin karar mekanizmalarının anlaşılabilirliği, özellikle klinik uygulamalar için güvenilirlik çerçevesinde son derece önem arz etmektedir. Bu nedenle ilerleyen araştırmalarda Grad-CAM, LIME gibi açıklanabilir yapay zekâ tekniklerinin entegrasyonu, modelin karar süreçlerini daha şeffaf hale getirerek kullanıcı güvenini ve klinik geçerliliği artıracaktır.

Diğer taraftan, bu çalışmada sınıflandırma yalnızca tek bir görev olarak ele alınmıştır. Ancak ilerleyen süreçte tümör tipiyle birlikte, tümörün büyüklüğü, konumu ve yayılım özelliklerinin de değerlendirildiği çok görevli öğrenme (multi-task learning) mimarilerinin geliştirilmesi, karar destek sistemlerinin çok daha kapsamlı görevleri aynı anda yerine getirmesine imkân sağlayacaktır. Ayrıca, işlem gücü sınırlı cihazlarda çalışabilecek şekilde optimize edilmiş modeller geliştirerek, gerçek zamanlı sınıflandırma sistemlerinin mobil ya da gömülü platformlara entegrasyonu da mümkün olabilir.

Sonuç olarak, bu tez çalışmasıyla yüksek doğrulukların elde edilmesiyle birlikte, geliştirilen modellerin de daha büyük, çok merkezli ve klinik doğrulama içeren veri setleri ile test edilmesi, hem model güvenilirliğini artıracak hem de yaygın kullanıma uygun hale getirilmesini destekleyecektir. Bu kapsamda, sunulan tez çalışması sadece literatüre katkı sağlamakla kalmayıp, buna ilave olarak gelecekteki daha kapsamlı ve ileri düzey araştırmalara da sağlam bir temel oluşturacağı düşünülmektedir.

KAYNAKÇA

- Abdelreheem, T. A., Salem, M. A., & Elnabawy, R. H. (2024, November). CNN Brain Tumor Classification Based on Masked Image Using U-Net Segmentation. In 2024 International Mobile, Intelligent, and Ubiquitous Computing Conference (MIUCC) (pp. 143-147). IEEE.
- Aboussaleh, I., Riffi, J., Fazazy, K. E., Mahraz, M. A., & Tairi, H. (2023). Efficient U-Net architecture with multiple encoders and attention mechanism decoders for brain tumor segmentation. *Diagnostics*, 13(5), 872.
- Ahuja, S., Panigrahi, B. K., & Gandhi, T. (2020, February). Transfer learning based brain tumor detection and segmentation using superpixel technique. In 2020 International Conference on Contemporary Computing and Applications (IC3A) (pp. 244-249). IEEE.
- Almadhoun, H. R., & Abu-Naser, S. S. (2022). Detection of Brain Tumor Using Deep Learning. *International Journal of Academic Engineering Research (IJAER)*, 6(3).
- Amin, J., Sharif, M., Gul, N., Yasmin, M., & Shad, S. A. (2020). Brain tumor classification based on DWT fusion of MRG sequences using convolutional neural network. *Pattern Recognition Letters*, 129, 115-122.
- Avanzo, M., Wei, L., Stancanello, J., Vallieres, M., Rao, A., Morin, O., ... & El Naqa, I. (2020). Machine and deep learning methods for radiomics. *Medical physics*, 47(5), e185-e202.
- Badža, M. M., & Barjaktarović, M. Č. (2020). Classification of brain tumors from MRG images using a convolutional neural network. *Applied Sciences*, 10(6), 1999.
- Benchari, M., & Totaro, M. W. (2024, July). MRG brain cancer image detection: Application of an integrated u-net and resnet50 architecture. In *International Conference on Artificial Intelligence in Medicine* (pp. 104-108). Cham: Springer Nature Switzerland.
- BOZBUĞA, N., & GÜLSEÇEN, S. TIP BİLİŞİMİ.

- Cherguif, H., Riffi, J., Mahraz, M. A., Yahyaouy, A., & Tairi, H. (2019, December). Brain tumor segmentation based on deep learning. In 2019 International Conference on Intelligent Systems and Advanced Computing Sciences (ISACS) (pp. 1-8). IEEE.
- Çinar, A., & Yildirim, M. (2020). Detection of tumors on brain MRG images using the hybrid convolutional neural network architecture. *Medical hypotheses*, 139, 109684.
- Cohen, J. (1992). Statistical power analysis. *Current directions in psychological science*, 1(3), 98-101.
- Çetin, N. K. (2020). Santral Sinir Sistemi Tümörlerinin Histopatolojik Dağılımı ve İnsidansı: Tek Merkezin 10 yıllık Retrospektif Analizi. *Dicle Tıp Dergisi*, 47(1), 178-193.
- Davenport, T., & Kalakota, R. (2019). The potential for artificial intelligence in healthcare. *Future healthcare journal*, 6(2), 94.
- Disci, R., Gurcan, F., & Soylu, A. (2025). Advanced brain tumor classification in MR images using transfer learning and pre-trained deep CNN models. *Cancers*, 17(1), 121.
- Eker, A. G., Pehlivanoglu, M. K., İnce, İ., & Duru, N. (2023, September). Deep learning and transfer learning based brain tumor segmentation. In 2023 8th International Conference on Computer Science and Engineering (UBMK) (pp. 163-168). IEEE.
- Geva, T. (2006). Magnetic resonance imaging: historical perspective. *Journal of cardiovascular magnetic resonance*, 8(4), 573-580.
- Grover, V. P., Tognarelli, J. M., Crossey, M. M., Cox, I. J., Taylor-Robinson, S. D., & McPhail, M. J. (2015). Magnetic resonance imaging: principles and techniques: lessons for clinicians. *Journal of clinical and experimental hepatology*, 5(3), 246-255.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).

- Huang, J., Shlobin, N. A., Lam, S. K., & DeCuypere, M. (2022). Artificial intelligence applications in pediatric brain tumor imaging: a systematic review. *World neurosurgery*, 157, 99-105.
- Hossain, M. S., Sabbir, M. S. I., Kobra, K. T., & Bandan, S. S. (2024). Advanced Brain Tumor Diagnosis: MRG Image Classification with Deep Learning Technology. *International Journal of Research and Innovation in Applied Science*, 9(8), 571-581.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Ishaq, A., Ullah, F. U. M., Hamandawana, P., Cho, D. J., & Chung, T. S. (2025). Improved EfficientNet Architecture for Multi-Grade Brain Tumor Detection. *Electronics*, 14(4), 710.
- Khan, H. A., Jue, W., Mushtaq, M., & Mushtaq, M. U. (2020). Brain tumor classification in MRG image using convolutional neural network. *Math. Biosci. Eng.*, 17(5), 6203-6216.
- Kibriya, H., Amin, R., Alshehri, A. H., Masood, M., Alshamrani, S. S., & Alshehri, A. (2022). A Novel and Effective Brain Tumor Classification Model Using Deep Feature Fusion and Famous Machine Learning Classifiers. *Computational Intelligence and Neuroscience*, 2022.
- Kim, S., Son, Y., Oh, J., Kim, S., Jang, W., Lee, S., ... & Yon, D. K. (2025). Global burden of brain and central nervous system cancer in 185 countries, and projections up to 2050: a population-based systematic analysis of GLOBOCAN 2022. *Journal of Neuro-Oncology*, 1-13.
- Krishnapriya, S., & Karuna, Y. (2023). Pre-trained deep learning models for brain MRG image classification. *Frontiers in Human Neuroscience*, 17, 1150120.
- Kumar, K. K., Dinesh, P. M., Rayavel, P., Vijayaraja, L., Dhanasekar, R., Kesavan, R., ... & Alhussen, A. (2023). Brain Tumor Identification Using Data Augmentation and Transfer Learning Approach. *Computer Systems Science & Engineering*, 46(2).

- Lapointe, S., Perry, A., & Butowski, N. A. (2018). Primary brain tumours in adults. *The Lancet*, 392(10145), 432-446.
- Mayerhoefer, M. E., Materka, A., Langs, G., Häggström, I., Szczypiński, P., Gibbs, P., & Cook, G. (2020). Introduction to radiomics. *Journal of Nuclear Medicine*, 61(4), 488-495.
- McFaline-Figueroa, J. R., & Lee, E. Q. (2018). Brain tumors. *The American journal of medicine*, 131(8), 874-882.
- Naser, M. A., & Deen, M. J. (2020). Brain tumor segmentation and grading of lower-grade glioma using deep learning in MRG images. *Computers in biology and medicine*, 121, 103758.
- Noreen, N., Palaniappan, S., Qayyum, A., Ahmad, I., Imran, M., & Shoaib, M. (2020). A deep learning model based on concatenation approach for the diagnosis of brain tumor. *IEEE Access*, 8, 55135-55144.
- Ohgaki, H. (2009). Epidemiology of brain tumors. *Cancer Epidemiology*, 323-342.
- Otsu, N. (1975). A threshold selection method from gray-level histograms. *Automatica*, 11(285-296), 23-27.
- Pravitasari, A. A., Iriawan, N., Almuhayar, M., Azmi, T., Irhamah, I., Fithriasari, K., ... & Ferriastuti, W. (2020). UNet-VGG16 with transfer learning for MRG-based brain tumor segmentation. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, 18(3), 1310-1318.
- Rehman, A., Khan, M. A., Saba, T., Mehmood, Z., Tariq, U., & Ayesha, N. (2021). Microscopic brain tumor detection and classification using 3D CNN and feature selection architecture. *Microscopy Research and Technique*, 84(1), 133-149.
- Rehman, A., Naz, S., Razzak, M. I., Akram, F., & Imran, M. (2020). A deep learning-based framework for automatic brain tumors classification using transfer learning. *Circuits, Systems, and Signal Processing*, 39(2), 757-775.
- Rogers, W., Thulasi Seetha, S., Refaee, T. A., Lieverse, R. I., Granzier, R. W., Ibrahim, A., ... & Lambin, P. (2020). Radiomics: from qualitative to quantitative imaging. *The British journal of radiology*, 93(1108), 20190948.

- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18* (pp. 234-241). Springer international publishing.
- Salehi, A. W., Khan, S., Gupta, G., Alabdullah, B. I., Almjally, A., Alsolai, H., ... & Mellit, A. (2023). A study of CNN and transfer learning in medical imaging: Advantages, challenges, future scope. *Sustainability*, *15*(7), 5930.
- Scapicchio, C., Gabelloni, M., Barucci, A., Cioni, D., Saba, L., & Neri, E. (2021). A deep look into radiomics. *La radiologia medica*, *126*(10), 1296-1311.
- Shoab, M. R., Elshamy, M. R., Taha, T. E., El-Fishawy, A. S., & Abd El-Samie, F. E. (2022). Efficient deep learning models for brain tumor detection with segmentation and data augmentation techniques. *Concurrency and computation: practice and experience*, *34*(21), e7031.
- Shyamalee, T., & Meedeniya, D. (2022). Glaucoma detection with retinal fundus images using segmentation and classification. *Machine Intelligence Research*, *19*(6), 563-580.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- Toğaçar, M., Ergen, B., & Cömert, Z. (2020). BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model. *Medical hypotheses*, *134*, 109531.
- Van Timmeren, J. E., Cester, D., Tanadini-Lang, S., Alkadhi, H., & Baessler, B. (2020). Radiomics in medical imaging—“how-to” guide and critical reflection. *Insights into imaging*, *11*(1), 1-16.

Weishaupt, D., Köchli, V. D., Marincek, B., Froehlich, J. M., Nanz, D., & Pruessmann, K. P. (2006). *How does MRG work?: an introduction to the physics and function of magnetic resonance imaging* (Vol. 2). Berlin: Springer.

Weiss, J., Schwartz, L. H., & Aerts, H. J. (2021). Radiomics.

Yi, Z., Long, L., Zeng, Y., & Liu, Z. (2021). Current advances and challenges in radiomics of brain tumors. *Frontiers in oncology*, 4161.

Yilmaz, A. (2021). Brain tumor detection from MRG images with using proposed deep learning model: the partial correlation-based channel selection. *Turkish Journal of Electrical Engineering and Computer Sciences*, 29(8), 2615-2633



ÖZGEÇMİŞ

1. Adı Soyadı: Ayşenur TOPBAŞ

| Derece | Alan | Üniversite | Yıl |
|-----------|--|---------------------------------------|------|
| Lisans | Bilgisayar Mühendisliği | İstanbul Sabahattin Zaim Üniversitesi | 2016 |
| Y. Lisans | Bilgisayar Bilimleri ve Mühendisliği (%30 İngilizce) | İstanbul Sabahattin Zaim Üniversitesi | 2019 |
| Doktora | Bilgisayar Bilimleri ve Mühendisliği (%30 İngilizce) | İstanbul Sabahattin Zaim Üniversitesi | |

4. Akademik Unvanlar:

Yardımcı Doçentlik Tarihi :

Doçentlik Tarihi :

Profesörlük Tarihi :

5. Yönetilen Yüksek Lisans ve Doktora Tezleri

5.1. Yüksek Lisans Tezleri

5.2. Doktora Tezleri

6. Yayınlar

6.1. Uluslararası hakemli dergilerde yayınlanan makaleler (SCI & SSCI & Arts and Humanities)

6.2. Uluslararası diğer hakemli dergilerde yayınlanan makaleler

6.3. Uluslararası bilimsel toplantılarda sunulan ve bildiri kitabında (*Proceedings*) basılan bildiriler

Gençdoğmuş, A., Keskin, Ş. R., Doğan, G., & Öztürk, Y. (2019, December). A data-driven approach to kinematic analytics of spinal motion. In 2019 IEEE International Conference on Big Data (Big Data) (pp. 2222-2229). IEEE.

Keskin, Ş. R., Gençdoğmuş, A., Yıldırım, B., Doğan, G., & Öztürk, Y. (2020, April). DNN and CNN approach for human activity recognition. In 2020 7th International Conference on Electrical and Electronics Engineering (ICEEE) (pp. 254-258). IEEE.

Topbař, A., Hameed, AA., & Jamil A.(2021). Hypermeters Optimization in Recurrent Neural Networks-LSTM Approach for Human Activity. International Conference on Computing and Machine Intelligence (ICMI 2021)

Topbař, A., Jamil, A., Hameed, A. A., Ali, S. M., Bazai, S., & Shah, S. A. (2021, October). Sentiment analysis for covid-19 tweets using recurrent neural network (rnn) and bidirectional encoder representations (bert) models. In 2021 International Conference on Computing, Electronic and Electrical Engineering (ICE Cube) (pp. 1-6). IEEE.

6.4. Yazılan uluslararası kitaplar veya kitaplarda bölümler

6.5. Ulusal hakemli dergilerde yayınlanan makaleler

6.6. Ulusal bilimsel toplantılarda sunulan ve bildiri kitabında basılan bildiriler

Topbař, A., & Bedir, S. (2025, Temmuz). *A comparative evaluation of pre-trained transfer learning methods in tumor classification from augmented brain MR images*. 16. Uluslararası İstanbul Bilimsel Çalışmalar Kongresi.

6.7. Diğer yayımlar

7. Projeler

Artırılmış MR Görüntüleri Üzerinde Beyin Tümörü Tespiti ve Sınıflandırılması İçin Radyomik Tabanlı Makine Öğrenmesi ve Ön Eğitimli Derin Öğrenme Modellerinin Kullanılması (İstanbul Sabahattin Zaim Üniversitesi Bilimsel Araştırma Projesi BAP300 (12/12/2024-Devam) Arařtırmacı/Bursiyer: TOPBAř AYŐENUR

TÜBİTAK 4005 Bilim ve Toplum Yenilikçi Eğitim Uygulamaları Destekleme Programı: Akademisyen ve Lisansüstü Öğrencilerine Yönelik Disiplinlerarası Bütünleştirilmiş Eğitim: R Programlama Dili ile Veri Analizi, TÜBİTAK PROJESİ, Eğitimci: GENÇDOĞMUŐ AYŐENUR, Yürütücü: DOĐAN GÜLÜSTAN, Eğitimci: ÖZDEMİR ŐEBNEM, (06/03/2019 - 23/03/2019) (ULUSAL)

Hareket KinematiĐi Veri Analizi, ARAŐTIRMA PROJESİ, Arařtırmacı: GENÇDOĞMUŐ AYŐENUR, Yürütücü: DOĐAN GÜLÜSTAN, (19/03/2019 - 02/04/2020) (ULUSAL)

TÜBİTAK 2209-A Üniversite Öğrencileri Arařtırma Projeleri Destekleme Programı: Kronik veya Potansiyel Bel Ağrısına Sahip Hastaların Sensörlerden Okunan Hareket KinematiĐi Verilerinin Analizi ve Derin Öğrenme ile Hareket

Tahmini Yapılması, TÜBİTAK PROJESİ, Danışman: GENÇDOĞMUŞ
AYŞENUR, (22/04/2019 - 30/07/2020) (ULUSAL)

8. İdari Görevler

9. Bilimsel ve Mesleki Kuruluşlara Üyelikler

10. Ödüller

