

**TÜMÖRLÜ BEYİN HÜCRELERİ TESPİTİNDE
ÖĞRENME AKTARIMIYLA DERİN SİNİR AĞLARININ
UYGULANMASI**

**APPLICATION OF DEEP NEURAL NETWORKS WITH
TRANSFER LEARNING IN THE DETECTION OF
TUMOR BRAIN CELLS**

BERKE YAĞMUR

DR.ÖĞR. ÜYESİ İBRAHİM ZOR

Tez Danışmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin
İstatistik Anabilim Dalı için Öngördüğü
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2023

ÖZET

TÜMÖRLÜ BEYİN HÜCRELERİ TESPİTİNDE ÖĞRENME AKTARIMIYLA DERİN SİNİR AĞLARININ UYGULANMASI

Berke YAĞMUR

Yüksek Lisans, İstatistik Bölümü

Tez Danışmanı: Dr. Öğr. Üyesi İbrahim Zor

Haziran 2023, 94 Sayfa

Bu tez, tıbbi görüntü analizinde derin öğrenme modellerinin etkinliğini ve uygulanabilirliğini incelemektedir. Özellikle, çeşitli türlerde tümörleri içeren manyetik rezonans görüntülerinin (MRI) sınıflandırılmasına odaklanmaktadır. Giriş bölümünde, tıbbi görüntü analizinin önemi, yapay zekâ ve derin öğrenmenin bu alandaki yükselişi ve bu çalışmanın amacı detaylı bir şekilde ele alınmıştır.

Tezde, beş popüler derin öğrenme modeli olan ResNet, EfficientNet, MobileNet, DenseNet ve InceptionV4 kullanılmıştır. Her bir model, ImageNet ağırlıklarıyla öğrenme aktarımı yöntemi kullanılarak eğitilmiş ve ImageNet ağırlıkları olmadan sıfırdan eğitilmiştir. Modellerin performansları, çeşitli tümör türlerini sınıflandırma doğruluğu üzerinden değerlendirilmiştir.

Sonuçlar genel olarak tüm metrikler üzerinden değerlendirilse de sınıfların dengesiz dağılımları sebebiyle F1-skor üzerinden nihai değerlendirme yapılmıştır. InceptionV4 modelinin ImageNet ağırlıklarıyla eğitildiğinde en yüksek genel başarı oranına (%96 F1-Skor) sahip olduğu gözlemlenmektedir. Diğer modeller de benzer şekilde yüksek başarı oranlarına sahip olmakla birlikte, bazı tümör türlerini sınıflandırmada zorlanmaktadırlar. Özellikle Granuloma T2 gibi belirli sınıflarda tüm modellerin performansı düşmüştür.

Tez ayrıca, öğrenme aktarımının, modellerin hızlı ve etkili bir şekilde eğitilmesine yardımcı olduğunu vurgulamaktadır. Bununla birlikte, özel veri setleri için model eğitimi

gerçekleřtirmenin ve hiper parametre ayarının modellerin performansını artırabileceđi belirtilmiřtir.

Tez sonunda, klinik uygulamalar için tmr sınıflandırmasında hangi derin đrenme modelinin veya modellerinin en uygun olduđuna dair deđerli bilgiler sađlanırken, bu modellerin sınırlamalarını ve zorluklarını anlamak gelecekteki arařtırmalara ve geliřtirmelere yn verebilir.

Bu alıřma, tıbbi grnt analizinde derin đrenmenin nemini vurgulamakta ve bu alanda yapılan arařtırmalara katkıda bulunarak hastalar için daha dođru teřhisler ve etkili tedavilerin nn amaktadır.

Anahtar Kelimeler: Grnt iřleme, makine đrenmesi, bilgisayarlı gr, đrenme aktarımı, derin đrenme

ABSTRACT

APPLICATION OF DEEP NEURAL NETWORKS WITH TRANSFER LEARNING IN THE DETECTION OF TUMOR BRAIN CELLS

Berke YAĞMUR

Master of Science, Department of Statistic

Supervisor: Dr. Öğr. Üyesi İbrahim ZOR

June 2023, 94 Pages

This thesis examines the effectiveness and applicability of deep learning models in medical image analysis. Specifically, it focuses on the classification of magnetic resonance images (MRI) containing tumors of various types. In the introduction section, the importance of medical image analysis, the rise of artificial intelligence and deep learning in this field, and the objective of this study are discussed in detail.

In the thesis, four popular deep learning models, namely ResNet, MobileNet, DenseNet, and InceptionV4, are utilized. Each model is trained using the transfer learning method with ImageNet weights and trained from scratch without ImageNet weights. The performance of the models is evaluated based on the accuracy of classifying various types of tumors.

Although the results are generally evaluated across all metrics, the final evaluation is done based on the F1-score due to the imbalanced distribution of the classes. It is observed that the InceptionV4 model has the highest overall success rate (%96 F1-score) when trained with ImageNet weights. While other models also exhibit comparably high accuracy rates, they face challenges in classifying certain types of tumors. Notably, the performance of all models dropped in certain classes such as Granuloma T2.

Additionally, the thesis emphasizes that transfer learning aids in the efficient and effective training of models. Moreover, it is noted that conducting model training for specific datasets and adjusting hyperparameters could enhance the performance of the models.

Ultimately, the thesis provides valuable insights into which deep learning model or models are most suitable for tumor classification in clinical applications, while understanding the limitations and challenges of these models can guide future research and developments.

This study highlights the importance of deep learning in medical image analysis and contributes to the field by paving the way for more accurate diagnoses and effective treatments for patients.

Keywords: Image processing, machine learning, computer vision, transfer learning, deep learning

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	iii
İÇİNDEKİLER	v
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	viii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
1.1. Çalışmanın Amacı.....	1
1.2. Tez Düzeni	2
1.3. Literatür Taraması.....	2
2. DERİN ÖĞRENME VE YAPAY SİNİR AĞLARI.....	8
2.1. Yapay Sinir Ağları ve Mimarileri	8
2.2. Öğrenme Süreçleri	9
2.3. Optimizasyon Teknikleri	10
2.4. Aktivasyon Fonksiyonları.....	13
2.5. Hiper Parametreler	17
2.6. Derin Öğrenme Tabanlı Görüntü Sınıflandırma	18
3. GÖRÜNTÜ VERİLERİNİN ÖN İŞLEME SÜREÇLERİ VE SINIFLANDIRMA MODELLERİNİN GELİŞTİRİLMESİ	23
3.1. Görüntü Verilerinin Toplanması ve Kaynakları	23
3.2. Görüntü Ön İşleme Teknikleri.....	23
3.3. Model Performans Metrikleri ve Değerlendirme.....	27
4. UYGULAMA	29
4.1. Veri Setleri ve Problem Tanımı	29
4.2. Kullanılan Ön İşleme Yöntemleri.....	32
4.3. Kullanılan Teknik Yöntemler ve Mimariler	33
4.3.1. EfficientNet Mimarisi	34
4.3.2. ResNet Mimarisi	35
4.3.3. DenseNet Mimarisi	37

4.3.4. MobileNet Mimarisi	38
4.3.5. InceptionV4 Mimarisi.....	39
4.4. Model Eğitimi ve Test Süreçleri	40
4.5. Deneysel Sonuçlar	43
4.5.1. 4 Sınıflı Veri Seti Deneysel Sonuçları	43
4.5.1.1. ResNet Modelinin ImageNet Ağırlıklarıyla Eğitimi	43
4.5.1.2. ResNet Modelinin ImageNet Ağırlıkları Olmadan Eğitimi.....	45
4.5.1.3. EfficientNetB1 Modelinin ImageNet Ağırlıklarıyla Eğitimi.....	50
4.5.1.4. EfficientNetB1 Modelinin ImageNet Ağırlıkları Olmadan Eğitimi	53
4.5.1.5. MobileNet Modelinin ImageNet Ağırlıklarıyla Eğitimi.....	57
4.5.1.6. MobileNet Modelinin ImageNet Ağırlıkları Olmadan Eğitimi	60
4.5.1.7. InceptionV4 Modelinin ImageNet Ağırlıklarıyla Eğitimi	64
4.5.1.8. DenseNet Modelinin ImageNet Ağırlıklarıyla Eğitimi	67
4.5.2. 44 Sınıflı Veri Seti Deneysel Sonuçları	71
4.5.2.1. ResNet Modelinin ImageNet Ağırlıklarıyla Eğitimi	71
4.5.2.2. ResNet Modelinin ImageNet Ağırlıkları Olmadan Eğitimi.....	74
4.5.2.3. MobileNet Modelinin ImageNet Ağırlıklarıyla Eğitimi	77
4.5.2.4. DenseNet Modelinin ImageNet Ağırlıklarıyla Eğitimi	80
4.5.2.5. InceptionV4 Modelinin ImageNet Ağırlıklarıyla Eğitimi	83
5. SONUÇLAR VE ÖNERİLER	86

ŞEKİLLER DİZİNİ

Şekil 2.1. Basit bir yapay sinir ağı	8
Şekil 2.2. Düzeltilmiş doğrusal birim aktivasyon fonksiyonu grafiği.....	14
Şekil 2.3. Sigmoid aktivasyon fonksiyonu grafiği	15
Şekil 2.4. Hiperbolik tanjant grafiği	15
Şekil 2.5. Sızdıran düzeltilmiş doğrusal birim aktivasyon fonksiyonu grafiği.....	16
Şekil 3.1. Gri tonlamalı örneği	24
Şekil 3.2. Beyin tümörü görselinde Histogram Eşitleme.....	25
Şekil 3.3. Görüntü matrisinde medyan filtreleme örneği.....	25
Şekil 4.1 Dört sınıflı veri setine ait örnek görseller	29
Şekil 4.2. Kırk dört sınıflı veri setine ait örnek görseller.....	30
Şekil 4.3. 44 sınıflı veri seti için eğitim bilgileri.....	32
Şekil 4.4. Uygulanan veri artırma ve dönüştürme yöntemleri örnek görseli	33
Şekil 4.5. EffcientNet Mimarisi	34
Şekil 4.6. ResNet Mimarisi	36
Şekil 4.7. DenseNet Mimarisi	37
Şekil 4.8. MobileNet Mimarisi.....	39
Şekil 4.9. Inceptionv4 Mimarisi	40
Şekil 4.10. ResNet Modeli Sınıflandırma Matrisi.....	44
Şekil 4.11. ResNet modeli için sınıflandırma matrisi	47
Şekil 4.12. EfficientNet için sınıflandırma matrisi.....	51
Şekil 4.13. EfficientNet modeli sınıflandırma matrisi.....	54
Şekil 4.14. MobileNet modeli sınıflandırma matrisi.....	58
Şekil 4.15. MobileNet sınıflandırma matrisi	61
Şekil 4.16. InceptionV4 modeli sınıflandırma matrisi	65
Şekil 4.17. DenseNet modeli sınıflandırma matrisi	68
Şekil 4.18. ResNet modeli sınıflandırma matrisi	72
Şekil 4.19. ResNet modeli sınıflandırma matrisi	75
Şekil 4.20. MobileNet sınıflandırma matrisi	78
Şekil 4.21. DenseNet modeli sınıflandırma matrisi	81
Şekil 4.22. InceptionV4 modeli sınıflandırma matrisi	84

ÇİZELGELER DİZİNİ

Çizelge 4.1. 4 sınıflı veri seti için eğitim bilgileri.....	31
Çizelge 4.2. ResNet modeli eğitim süreci.....	43
Çizelge 4.3. ResNet Modeli Sınıflandırma Raporu	45
Çizelge 4.4. ResNet modeli eğitim süreci.....	46
Çizelge 4.5. ResNet modeli sınıflandırma raporu	48
Çizelge 4.6. EfficientNet için eğitim süreci.....	50
Çizelge 4.7. EfficientNet için sınıflandırma matrisi.....	52
Çizelge 4.8. EfficientNet modeli eğitim süreci.....	53
Çizelge 4.9. EfficientNet modeli sınıflandırma raporu	55
Çizelge 4.10. MobileNet modeli eğitim süreci	57
Çizelge 4.11. MobileNet modeli sınıflandırma raporu.....	59
Çizelge 4.12. ImageNet ağırlıkları kullanılmayan MobileNet modeli için eğitim süreci.....	60
Çizelge 4.13. MobileNet sınıflandırma raporu	62
Çizelge 4.14. InceptionV4 modeli için eğitim süreci.....	64
Çizelge 4.15. InceptionV4 sınıflandırma raporu	66
Çizelge 4.16. DenseNet modeli eğitim süreci.....	67
Çizelge 4.17. DenseNet modeli sınıflandırma raporu	69
Çizelge 4.18. ResNet modeli eğitim süreci	71
Çizelge 4.19. ResNet modeli sınıflandırma raporu	73
Çizelge 4.20. ResNet modeli eğitim süreci	74
Çizelge 4.21. ResNet modeli sınıflandırma raporu	76
Çizelge 4.22. MobileNet modeli eğitim süreci	77
Çizelge 4.23. MobileNet sınıflandırma raporu	79
Çizelge 4.24. DenseNet modeli eğitim süreci.....	80
Çizelge 4.25. DenseNet modeli sınıflandırma raporu	82
Çizelge 4.26. InceptionV4 modeli eğitim süreci	83
Çizelge 4.27. InceptionV4 modeli sınıflandırma raporu	85
Çizelge 5.1. 4 sınıflı veri kümesi için performans karşılaştırması.....	86
Çizelge 5.2. 44 sınıflı veri seti için performans karşılaştırması.....	87

SİMGELER VE KISALTMALAR

Kısaltmalar

CNN	Evrişimli Yapay Sinir Ağları
GLCM	Gri Tonlamalı Eş-Oluşum
IKMC	İyileştirilmiş K Ortalama Kümeleme
BP	Geri yayılım
UNet	U-shaped Network
RCNN	Bölge tabanlı evrişimli sinir ağı
GWO	Gri Kurt Optimizasyonu
SSO	Sosyal Örümcek Optimizasyonu
CNN-LSTM	Evrişimli Yapay Sinir Ağı – Uzun Kısa Dönemli Hafıza
VGG	Visual Geometry Group
RNN	Geri Beslemeli Ağlar
GAN	Üretken Çekişmeli Ağ
SVM	Destek Vektör Makineleri
GAM	Gradyan Farkındalık Azaltma
IFC	Aralıklı Tam Bağlantılı Katman
ACO	Karınca Koloni Optimizasyonu
LSTM	Uzun Kısa Vadeli Bellek Ağları
MSE	Ortalama Kare Hata
SGD	Stokastik Gradyan İnişi
ReLU	Düzeltilmiş Doğrusal Birim
Leaky ReLU	Sızdıran Düzeltilmiş Doğrusal Birim
ResNet	Artık Ağlar
MobileNet	Mobil Ağlar
DenseNet	Yoğun Ağlar
EfficientNet	Etkili Ağlar
InceptionV4	Başlangıç Ağlar
MBConv	Mobil ters darboğaz evrişim

1. GİRİŞ

1.1. Çalışmanın Amacı

Tıbbi görüntü analizi, modern tıbbın en kritik ve karmaşık bileşenlerinden biridir. Yıllar içinde, tıbbi görüntüleme teknolojileri sayesinde, doktorlar hastalıkları daha doğru bir şekilde teşhis edebilir ve etkili tedaviler önerebilirler. Ancak, insan gözünün sınırlamaları nedeniyle, tıbbi görüntülerin manuel analizi hatalı veya eksik olabilir. Yapay zekâ ve özellikle derin öğrenme, bu sorunların üstesinden gelmede önemli bir rol oynamaktadır. Derin öğrenme algoritmaları, karmaşık görüntü verilerini analiz ederek daha doğru ve hızlı teşhisler koymamıza olanak tanır. Bu tez, tıbbi görüntülerde tümör sınıflandırmasını derin öğrenme modelleri aracılığıyla otomatikleştirmeyi amaçlamaktadır.

Kullanılan veri setleri, çeşitli türlerde tümörleri içeren manyetik rezonans görüntüleri (MRI) barındırmaktadır. Manyetik rezonans görüntüleme, dokuların ve organların detaylı görüntülerini elde etmek için kullanılan güçlü bir tıbbi görüntüleme tekniğidir. Bu modellerin görevi, bu görüntülerdeki tümörleri yüksek başarı ile tespit edip sınıflandırmaktır.

Bu çalışmada, ResNet (Artık Ağlar), MobileNet (Mobil Ağlar), DenseNet (Yoğun Ağlar), EfficientNet (Etkili Ağlar) ve InceptionV4 (Başlangıç Ağlar) gibi popüler derin öğrenme modelleri incelenmektedir. Her bir modelin yapılandırılması, eğitimi ve performansı detaylı bir şekilde değerlendirilmektedir. Bu modeller, kendi başlarına etkileyici sonuçlar verebilmekle birlikte, çeşitli tümör türlerine olan duyarlılıkları farklılık gösterir. Öğrenme aktarımı, bu modellerin başarısını artırmada önemli bir araç olarak değerlendirilmektedir. Öğrenme aktarımı, önceden eğitilmiş modelleri ve ağırlıkları kullanarak, modelin daha hızlı ve etkili bir şekilde öğrenmesini sağlar.

Bu tezin bulguları, klinik uygulamalara yönelik olarak, tümör tespiti ve sınıflandırmasında hangi derin öğrenme modelinin veya modellerinin en uygun olduğuna dair değerli bilgiler sağlayabilir. Ayrıca, bu modellerin sınırlamalarını ve zorluklarını anlamak, gelecekteki araştırmalara ve geliştirmelere yön verebilir.

Özetle, bu tez, tıbbi görüntü analizinde derin öğrenmenin kritik rolünü ve değerini vurgulamaktadır. Tümör sınıflandırmasında kullanılan farklı derin öğrenme modellerinin analizi, bu alanda atılacak adımlar için bir temel oluşturur. Bu, hastalar için daha doğru teşhisler, daha etkili tedaviler ve sonuçta daha iyi sağlık sonuçlarına yol açabilir.

1.2. Tez Düzeni

Tezin ilk bölümünde çalışmanın amacı belirtilmektedir. Ayrıca tezin nasıl düzenlendiği hakkında bilgi verilmekte ve derin öğrenme ile tıbbi görüntü analizi için mevcut literatürün bir taraması yapılmaktadır.

İkinci bölüm, yapay sinir ağlarını ve mimarilerini kapsamlı bir şekilde incelemektedir. Öğrenme süreçleri, optimizasyon teknikleri ve aktivasyon fonksiyonları üzerinde durularak, bu tekniklerin nasıl çalıştığı ve nasıl kullanıldığı açıklanmaktadır.

Üçüncü bölüm, görüntü verilerinin toplanması, ön işleme teknikleri ve veri artırma yöntemleri gibi konuları içermektedir. Aynı zamanda evrişimli sinir ağları ile derin öğrenme tabanlı görüntü sınıflandırma yöntemlerini ele almaktadır

Dördüncü bölüm, gerçek veri setleri üzerinde derin öğrenme modellerinin uygulanması aşamasını kapsamaktadır. Kullanılan ön işleme yöntemleri ve teknikler, model eğitimi ve test süreçleri bu bölümde açıklanmaktadır.

Beşinci ve son bölümde, çalışmanın sonuçları özetlenir ve gelecekteki araştırmalar için önerilerde bulunulur.

Bu yapı, tezi anlaşılır ve takip etmesi kolay bir şekilde organize ederken, derin öğrenmenin tıbbi görüntü analizinde nasıl kullanılabileceği konusunda kapsamlı bir bakış sağlar.

1.3. Literatür Taraması

Tandel ve ark. [1], çalışmalarında, evrişimli yapay sinir ağlarında (CNN) üstün performans elde etmek için eğitim parametrelerinin önemini ve en uygun parametre

değerlerinin belirlenmesini incelemektedir. Veri bölümlendirme protokolleri, öğrenme oranı ve grup boyutu gibi eğitim parametrelerinin optimizasyonu üzerine yoğunlaşmıştır. Çalışmada beş farklı veri seti üzerinde klasik makine öğrenimi ve derin öğrenme yöntemleri denenmiş olup, evrişimli yapay sinir ağı tabanlı modellerde üstün performans elde etmek için parametre seçiminin önemine vurgu yapılmıştır.

Mondal ve Shrivastava [2], çalışmalarında, beyin tümörü tespiti için evrişimli yapay sinir ağı tabanlı bir model olan BMRI-Net'i önermektedirler. Yapay sinir ağlarında gerçekleşen nöron ölümleri ve eğitim verisindeki örneklerin bir bölümüne çok uyum sağlamasının ardından modelin genelleştirme performansının düşmesi sorunlarına çözüm bulmak amacıyla, "The Parametric Flatten-p Mish" (PFpM) adlı yeni bir parametrik aktivasyon fonksiyonu önermektedirler. Çalışma özelinde tasarladıkları modelin mimarisini güncel evrişimli yapay sinir ağı mimarileriyle ve çeşitli aktivasyon fonksiyonlarıyla karşılaştırmışlardır. İki farklı veri seti kullanılmış, ikisinde de yüksek başarı oranlarına ulaşılmıştır.

Vankdothu ve ark. [3], çalışmalarında, verideki gürültü sorununu çözmek için filtreleme uygulamıştır. Öznitelik çıkarımı yapmak için Gri Tonlamalı Eş-oluşum (GLCM) matrisi kullanılmıştır. Görüntü bölütleme konularında ise iyileştirilmiş K-ortalama kümeleme (IKMC) algoritmasından yararlanmışlardır. Veri ön işleme kısımlarına ağırlık veren çalışma da daha önceden aynı veri seti ile eğitilen geri yayılım (BP), U-shaped Network (UNet) ve bölge tabanlı evrişimli sinir ağı (RCNN) modellerden %95,17'lik başarı oranıyla daha başarılı olmuştur.

Sun ve ark. [4], çalışmalarında, belirli katmanlara sahip özelleştirilmiş bir evrişimli yapay sinir ağı modeli önermişlerdir. Bu özelleştirilmiş model katmanlarının her birinin kendine özgü görevleri vardır. İlk iki katman öznitelik çıkarımı yaparken, üçüncü ve dördüncü katmanlar tümör olan bölgelerin lokalizasyonunu gerçekleştirmektedir. Beşinci, altıncı ve yedinci katmanlar ise iyileştirilmiş sınıflandırma gerçekleştirmektedir. Bu yaklaşım ile hesaplama ve model doğruluğu açısından yüksek verimli bir yöntem önerilmiştir.

Vankdothu ve Hameed [5], çalışmalarında, beyin tümörü tespiti için bölütlenme ve optimizasyon üzerinde çözümler önermiştir. Çalışmasında bir bulanık mantık sistemini

yapay sinir ağılarıyla birleştiren bir zeka modeli kullanmışlardır. Bu sayede veriler arasında doğrusal olmayan ilişkileri saptama konusunda iyi bir önerme sunmaktadırlar. Bölütlenme kısmında ise farklı bölümlerin algılanmasını sağlamak adına bir kümeleme algoritması olan Bulanık C-Ortalamlar (Fuzzy C-Means) kullanarak her pikselin ait olduğu kümelerle yakınlık derecelerini incelemiştir. Çalışmalarında optimizasyon algoritmaları kısmında ise Gri Kurt Optimizasyonu (GWO) ve Sosyal Örümcek Optimizasyonu (SSO) kullanarak karmaşık ve çok boyutlu optimizasyon problemlerine de çözüm yolu önermiştir.

Kazemi ve ark. [6], çalışmada iki farklı veri kümesi, iki farklı sınıflandırma türü (çoklu ve ikili), bir çok önceden eğitilmiş model ağırlıklarıyla beslenen derin öğrenme algoritmaları kullanılmıştır. Paralel bir derin öğrenme modeli kurgulanarak, otomatize edilmiş özellik çıkarımı ile birlikte çoklu sınıflandırma da daha yüksek başarı oranlarına ulaşılmıştır. Çalışmada önerilen evrişimli yapay sinir ağı mimarisinin diğer çalışmalara göre daha basit kurgulanmış olması nedeniyle daha düşük kaynak istemektedir.

Fernando ve Tsokos [7], çalışmada modern derin öğrenme uygulamaları, ileri istatistik yöntemlerini ve olasılıksal derin öğrenme yöntemlerini etkin bir şekilde birleştirmeyi önermişlerdir. Bu yönde yapılacak gelecekteki araştırmalar için kapsamlı bir teorik bilgi ortaya koymuşlardır.

Pacheco ve ark. [8], görüntüdeki ön işleme adımlarından biri olan beyin dokusu dışarısındaki diğer yapıları çıkarmak için kullanılan bir bölütlenme yönteminin model başarısına nasıl etkilediğini araştırmıştır. Bu bölütlenme yöntemlerinde kötü seçilmiş bir yöntemin modelin başarısını ne ölçüde etkilediğini incelemiştir. Otomatik bölütlenme çalışmalarının da manuel olarak ayarlanan bölütlenme teknikleriyle aynı başarıya yaklaştığı vurgulanmaktadır.

Havaei ve ark. [9], çalışmalarında beyin bölütlenmesinde ön işleme süreçlerinin uzun süreler alabildiğini bildiklerini göstererek, bu sürede iki yönlü bir evrişimli yapay sinir ağı mimarisi eğitmişlerdir. Bu mimarideki son katman tamamen bağlantılı bir evrişimli uygulamadır. Bu katman sayesinde 40 kat hızlı bir çözüm sunmuşlardır. Ayrıca iki

modelli bir çözüm yolu geliştirerek (bir modelin çıktısı diğer modelin girdisi oluyor) kademeli bir mimari tasarlamışlardır.

Vankdothu ve ark. [10], birleşik bir çözüm olarak evrişimli yapay sinir ağı – uzun kısa dönemli hafıza (CNN-LSTM) modeli geliştirmişlerdir. Daha önce yapılan aynı model çalışmalarındaki başarı oranını arttırmayı hedeflemişlerdir. Buradaki yapıda evrişimli yapay sinir ağlarının zaman serileri kapsamındaki gözlemler arasındaki ilişkileri anlama kabiliyetiyle başarıyı arttırmışlardır.

Dang ve ark. [11], temelde üç aşamalı bir çözüm önermişlerdir. İlk aşamada UNet mimarisi ile ön işleme konuları ele alınmış, ikinci aşamada beyin dokusu olmayan bölgelerin çıkarılması, üçüncü aşamada ise Görsel Geometri Grubu (VGG) ve GoogleNet ile yüksek ve düşük gliomların sınıflandırılması yapılmıştır. Çalışma ışığında VGG algoritmasının ağırlık gösterdiği alanları lezyonlu bölgeler olarak tespit ederken, GoogleNet algoritmasının ise daha geniş bölgelerde tarama yaptığını ortaya koymuşlardır.

Devi ve ark. [12], gürültü ve bulanıklık gibi modelin performansına doğrudan etki eden sorunları azaltmak adına Ortanca Değer (Medyan) Filtresi ve Uyarlamalı İki Yönlü (Bilateral) Filtre kullanılmıştır. SWPT (Stationary Wavelet Packet Transform) ile MR görüntülerindeki farklı dokuların ayrıştırılması için kullanılmıştır. CNN-LSTM modeli ile SWPT uygulaması yüksek kazanım sağlamıştır.

Naser ve Deen [13], düşük sınıf gliomların sınıflandırılmaları üzerine çalışmalarını gerçekleştirmişlerdir. Evrişimli sinir ağı mimarisine sahip UNet ve VGG16 algoritmaları geliştirerek öğrenme aktarımı uygulaması önermişlerdir.

Jiang ve ark. [14], çift yönlü çözme mimarisine sahip olan DDU-Net algoritmasını önermektedir. Çalışmadaki ana amaç bölütlenme başarısını arttırmak için iki kenar temelli bir optimizasyon stratejisi kullanmaktır. En öne çıkan kısım ise öz-adaptif dengeleme sınıf ağırlık katsayısını, entropi kaybı fonksiyonuna eklemeleridir. Bu yöntem ile Dice benzerlik katsayısı açısından ideal bir performans elde etmişlerdir.

Ma ve Zhang [15], hem teknik doğruluğa hem de verimliliğe odaklanmıştır. Veri işleme adımlarını otomatize eden bir yaklaşım sunmuşlardır. Karmaşıklığı azaltmak adına LYOLOv4-RNN birleşiminden oluşan bir mimari ile çalışmalarını gerçekleştirmişlerdir. Hafif bir sinir ağı ile otomatize edilmiş veri ön işleme yöntemlerinin birlikte kullanılarak hızlı sonuçlar alınabileceğini göstermişlerdir.

Abirami ve Vankatesan [16], beyin tümörü tespitinde tümörün şiddetini ölçmek üzerine yaklaşımlar geliştirmişlerdir. Üretken Çekişmeli Ağ (GAN) temelli Sınır Çobanı Ateş Böceği (Border Collie Firefly) algoritması adlı yeni bir yaklaşım önermektedirler. Gürültüyü Laplace filtresi uygulayarak giderip, Derin Ortak Model (Deep Joint Model) kullanarak bölütlenme işlemini gerçekleştirmişlerdir. Elde edilen çıkarılmış özellikler Destek Vektör Makineleri (SVM) algoritmasına girdi olarak verilir.

Tang ve ark. [17], çalışmalarında, beyin tümörlerinin yapay zeka algoritmalarıyla tespiti konularında genelleşmiş öznelilik çıkarımı sırasındaki konum kaybı, ölçek ilgili keskinlik sorunları ve tam bağlantılı katmanlar tarafından oluşan parametre gereksizliği konularına farklı yaklaşımlarla çözüm önermişlerdir. Ölçek bağımlılığını çözmek ve modelin genelleme başarısını arttırmak üzere Gradyan Farkındalık Azaltma (GAM) optimizasyon algoritması, gereksiz özellik kaybını önlemek için Aralıklı Tam Bağlantılı Katman (IFC) önerilmiştir. Uygulanan değerlendirmede BraTS2019 (Multimodal Brain Tumor Segmentation Challenge 2019) veri setinde GAM-SpCaNet, SE-ResNeXt-MLT, FCNN-CRFs, KSVM-SSD ve Ensemble modelleriyle karşılaştırılmıştır. %99,28 gibi bir başarı oranı yakalayarak getirdiği yaklaşımlar ile diğer modellerden yüksek bir başarı oranına sahip olmuştur.

Zulfiqar ve ark. [18], çalışmalarında, önceden eğitilmiş EfficientNet modelleri üzerinde (B0-B4) öğrenme aktarımı (Transfer Learning) gerçekleştirmişlerdir. Görüntülerdeki tümör bölgelerinin lokalizasyonunu gerçekleştirerek başarı oranını arttırmışlardır.

Anaya-Isaza ve ark. [19], çalışmalarında, farklı veri kümeleri üzerinde çalışıp, hem ikili hem de çoklu sınıflandırma konularında modeller eğitmişlerdir. Çalışmalarında yedi farklı sinir ağı eğitmişlerdir, bunların arasından InceptionResNetV2 diğerlerinden daha iyi performans göstermiş ve %97 başarı oranına ulaşmıştır. Aynı çalışma için farklı bir

veri kümesi kullanılarak başarı oranı %6 oranında arttırılmıştır. Kullandıkları bir diğer veri kümesinde, FLAIR (Fluid-Attenuated Inversion Recovery) kazanım dizisinin daha yüksek başarı getirdiği öne sürülmüştür. Çalışma neticesinde Çapraz-Dönüşüm (Cross-Transformer) ağının diğer ağlara performans avantajı ile üstünlük sağladığı görülmüştür.


Mehnatkesh ve ark. [20], çalışmalarında, daha önceden eğitilmiş optimizasyon temelli derin evrişimli ResNet modelini minimum düzeyde ön işleme yaparak eğitmişlerdir. Eğittikleri modelin hiper parametrelerini optimize etmek için Karınca Koloni Optimizasyonunu (ACO) kullanmışlardır. Kurguladıkları model yapısında artan yakınsama hızı, başarı ve yeniden üretilebilirliği ACO algoritması kullanarak maksimize etmişlerdir.

2. DERİN ÖĞRENME VE YAPAY SİNİR AĞLARI

2.1. Yapay Sinir Ağları ve Mimarileri

Yapay Sinir Ağları, insan beyninin işleme ve öğrenme yeteneklerini modellemeye çalışan ve doğal sinir sistemlerine dayalı olarak tasarlanmış yöntemlerdir [21]. Yapay sinir ağlarının temel yapı taşı olan nöronlar, gelen sinyalleri alarak, bunları amaca yönelik işleyerek ve belirli bir eşik değerini aşan sinyalleri sonraki nöronlara ileterek çalışırlar.

Yapay sinir ağları, genellikle katmanlar halinde düzenlenmiş nöronlarla temsil edilir ve bu katmanlar giriş, çıkış ve gizli katmanlar olarak ayrılır (Şekil 2.1). Giriş katmanı, veri kümesinin özelliklerini alır ve bu özellikler gizli katmanlardaki nöronlara iletilir. Gizli katmanlar, çeşitli hesaplama yöntemleri kullanılarak veri kümesindeki özelliklerin daha yüksek düzeyde temsillerini öğrenir ve öğrenilen bu temsiller çıkış katmanına aktarılır. Çıkış katmanı, belirli bir göreve (ör. sınıflandırma, regresyon) uygun çıktılar üretir [22].



Şekil 2.1. Basit bir yapay sinir ağı

Yapay sinir ağları, mimarilerine ve öğrenme yöntemlerine göre çeşitli şekillerde sınıflandırılabilir. Bazı temel yapay sinir ağı mimarileri şunlardır:

- Tek katmanlı beslemeli ileri ağlar (Perceptron)
- Çok katmanlı beslemeli ileri ağlar (Multilayer Perceptron, MLP)
- Geri beslemeli ağlar (Recurrent Neural Networks, RNN)
- Evrişimli Sinir Ağları (Convolutional Neural Networks, CNN)
- Uzun Kısa Vadeli Bellek ağları (Long Short-Term Memory, LSTM)

- Dikkat mekanizmaları ile artırılmış ađlar (Transformer, Attention-based models)

Yapay sinir ađı mimarileri, veri kümesi ve uygulama alanına bađlı olarak farklılık gösterebilir ve özelleştirilebilir. Bu tezde, beyin tümörü sınıflandırması için evrişimli sinir ađları ve öğrenme aktarımı yöntemlerinin kullanılması üzerinde durulacaktır.

2.2. Öğrenme Süreçleri

Yapay sinir ađlarının öğrenme süreçleri, ađlıkların ve yanlılıkların güncellenmesiyle gerçekleşir. Bu süreç, öğrenme oranı ve optimizasyon tekniklerine bađlıdır [29].

Bu bölümde, görüntü sınıflandırması için kullanılacak olan derin öğrenme modelinin öğrenme süreçleri ve optimizasyon teknikleri incelenmiştir. Bu kapsamda, en uygun optimizasyon algoritmasının seçilmesi ve öğrenme oranının ayarlanması üzerinde durulacaktır.

İleri Yayılım

İleri yayılım, sinir ađındaki nöronların katmanlar arası bađlantıları ve aktivasyon fonksiyonları kullanarak girdi verilerini çıktıya dönüştürme sürecidir [21]. İleri yayılım, ađın tahminlerini üretmek ve kayıp fonksiyonu deđerini hesaplamak için kullanılır.

Geri Yayılım

Geri yayılım, ađın hatalarını geriye dođru yayarak ve zincirleme türev kuralını kullanarak, her bir parametrenin kayıp fonksiyonuna göre gradyanını hesaplamak için kullanılan bir algoritmadır [30]. Geri yayılım, modelin parametrelerini güncellemek için kullanılır.

Kayıp Fonksiyonları

Kayıp fonksiyonları, modelin tahminlerinin gerçek deđerlerden ne kadar farklı olduğunu ölçen fonksiyonlardır [21]. En yaygın kullanılan kayıp fonksiyonları arasında ortalama kare hata (MSE) ve çapraz entropi bulunmaktadır.

2.3. Optimizasyon Teknikleri

Optimizasyon teknikleri, sinir ağının performansını en üst düzeye çıkarmak ve kayıp fonksiyonunu en aza indirmek için ağırlık ve yanlılık değerlerinin nasıl güncelleneceğini belirler. [44] Çeşitli optimizasyon teknikleri bulunmaktadır, bunlardan bazıları şunlardır:

- Gradyan İnişi (Gradient Descent)
- Stokastik Gradyan İnişi (Stochastic Gradient Descent, SGD)
- Momentum ile Gradyan İnişi
- RMSprop
- Adam (Adaptive Moment Estimation)

Bu optimizasyon algoritmalarının her biri, farklı avantajlar ve dezavantajlar sunar. Örneğin, Adam optimizasyon algoritması, adaptif öğrenme oranları ve momentum ile çalışarak, genellikle daha hızlı ve daha iyi performans sergiler [29].

Stokastik Gradyan İnişi

Stokastik Gradyan İnişi, modelin parametrelerini kayıp fonksiyonunun gradyanı ile ölçeklendirerek güncelleyen temel bir optimizasyon algoritmasıdır [31]. Stokastik Gradyan İnişi, rastgele seçilen örnekler veya mini veri alt küme örnekleri üzerinde çalışarak, modelin eğitim sürecini hızlandırır ve genelleme kabiliyetini artırır. Matematiksel formülü Eşitlik 2.1'de verilmiştir.

$$\theta(t + 1) = \theta(t) - \eta(t)\nabla L(\theta(t), x_i, y_i) \quad (2.1)$$

θ , ilgili modelin parametrelerini ifade etmektedir. t iterasyon sayısını belirtmekle beraber her bir iterasyonda ne kadar hızlı ilerleneceğini belirleyen ise $\eta(t)$ yani öğrenme hızıdır. $\nabla L(\theta(t), x_i, y_i)$: Kayıp fonksiyonunun gradyanıdır. Bu, model parametrelerine göre türev olarak hesaplanır.

Momentum

Momentum, Stokastik Gradyan İnişine hızlanma terimi ekleyerek, ağırlık yerel minimumlardan ve düşük gradyan bölgelerinden daha hızlı çıkmasına yardımcı olan bir optimizasyon tekniğidir [32]. Momentum, geçmiş gradyanları hafızada tutarak ve

gradyanlar yönünde düzgün bir hareket sağlayarak, parametre güncellemelerini optimize eder.

θ , ilgili modelin parametrelerini ifade etmektedir. İterasyon sayısı t ile ifade edilir ve başlangıçta 0 değerini alır. Başlangıç momentumu vektörü olarak ifade edilen $v(0)$ 0 olarak atanır. Kayıp fonksiyonunun gradyanı hesaplanır.

Eşitlik 2.2'deki denklem bir önceki adımdaki momentum değeri $v(t)$ ve öğrenme hızı η ile çarpılan mevcut adımdaki kaybın (L) türevinin birleşimini kullanarak bir sonraki adımda momentum değerini ($v(t+1)$) nasıl hesaplayacağımızı gösterir. Eşitlik 2.3'te ise mevcut adımdaki parametre değerine ($\theta(t)$) momentum terimini ($v(t+1)$) ekleriz.

$$v(t + 1) = \gamma v(t) - \eta \nabla L(\theta(t)) \quad (2.2)$$

$$\theta(t + 1) = \theta(t) + v(t + 1) \quad (2.3)$$

Adaptif Gradyan

Adaptif Gradyan, her parametre için adaptif bir öğrenme oranı sağlayarak, sık görülen özellikler için küçük ve nadir görülen özellikler için büyük güncellemeler yapar [33]. Bu yöntem, özellikle veri setinin özellik dağılımının dengesiz olduğu durumlarda etkilidir.

Eşitlik 2.4'te bulunan $G(t)$ toplam gradyan karesinin hesaplanmasını belirtir. Burada, $G(t-1)$ bir önceki adımda toplanan gradyan karelerini temsil eder ve $[\nabla L(\theta(t))]^2$, mevcut adımda hesaplanan gradyanın karesini ifade eder. Bu gradyanlar, her bir parametre için birikir ve bu da Adaptif Gradyan'ın "adaptif" olmasını sağlar. Yüksek gradyanlarla sıkça güncellenen parametreler daha düşük öğrenme hızına sahip olacaktır. Eşitlik 2.5'te parametrelerin güncellendiği kısım verilmiştir. Öğrenme hızı, her bir parametrenin birikmiş gradyanının kare kökü ile ölçeklenir, bu da daha az sıklıkta güncellenen parametrelerin daha hızlı öğrenmesini sağlar.

$$G(t) = G(t - 1) + [\nabla L(\theta(t))]^2 \quad (2.4)$$

$$\theta(t + 1) = \theta(t) - (\eta / \sqrt{G(t) + \epsilon}) * \nabla L(\theta(t)) \quad (2.5)$$

RMSprop

RMSprop, Adaptif Gradyan'ın öğrenme oranı düşüşünün hızını düşürerek, daha uzun eğitim süreçleri için uygun bir optimizasyon algoritması sunar [34]. RMSprop, gradyanların karesinin hareketli ortalamasını kullanarak, her parametre için adaptif öğrenme oranı sağlar.

Eşitlik 2.6'da $E(t)$ olarak belirtilen ifade hareketli ortalamasının hesaplanmasını belirtir. Bu hareketli ortalama, önceki hareketli ortalamaya ($E(t-1)$) ve mevcut adımda hesaplanan gradyanın karesinin $(1 - \beta)$ oranına bağlı olarak güncellenir. β burada yavaşlama faktörü veya momenti olarak hizmet eder ve genellikle 0.9 gibi bir değer alır.

Eşitlik 2.7 ise parametrelerin güncellenmesini belirtir. Burada, η öğrenme hızını temsil eder. Öğrenme hızı, her bir parametrenin hareketli ortalamasının kare kökü ile ölçeklenir. ε (genellikle çok küçük bir değer), paydanın sıfır olmasını önlemek için eklenir, böylece gradyanın sıfıra bölünmesi engellenir.

$$E(t) = \beta * E(t - 1) + (1 - \beta) * [\nabla L(\theta(t))]^2 \quad (2.6)$$

$$\theta(t + 1) = \theta(t) - (\eta / \sqrt{E(t) + \varepsilon}) * \nabla L(\theta(t)) \quad (2.7)$$

Adam

Adam, hem momentum hem de RMSprop tekniklerini birleştirerek, her parametre için adaptif öğrenme oranı ve momentum sağlayan bir optimizasyon algoritmasıdır [29]. Adam, farklı problemler için iyi performans gösteren ve genellikle hızlı ve etkili bir optimizasyon sağlayan popüler bir yöntemdir.

Eşitlik 2.8 ve Eşitlik 2.9 birinci ve ikinci momentin (veya gradyanın hareketli ortalamasının) hesaplanmasını belirtir. Eşitlik 2.10 birinci momentin, Eşitlik 2.11 ise ikinci momentin yanlılık düzeltmesini ifade eder. Düzeltme, başlangıçtaki ağırlıklı değerlerin 0 olduğu durumu dikkate alır. Eşitlik 2.12 ise parametrelerin güncellenmesini belirtir. Her bir parametre, öğrenme hızı ile çarpılan ve düzeltmeli ilk moment tarafından ölçeklenen bir adım boyunca hareket eder. Bu hareket, düzeltmeli ikinci momentin kare kökü tarafından ölçeklenir. Bu ölçeklendirme, her bir parametre için adaptif bir öğrenme hızı sağlar.

$$m(t) = \beta_1 * m(t - 1) + (1 - \beta_1) * \nabla L(\theta(t)) \quad (2.8)$$

$$v(t) = \beta_2 * v(t - 1) + (1 - \beta_2) * [\nabla L(\theta(t))]^2 \quad (2.9)$$

$$m^t = \frac{m(t)}{(1 - \beta_1^t)} \quad (2.10)$$

$$v^t = \frac{v(t)}{(1 - \beta_2^t)} \quad (2.11)$$

$$\theta(t + 1) = \theta(t) - \eta * \frac{m^t}{(\sqrt{v^t} + \varepsilon)} \quad (2.12)$$

2.4. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, yapay sinir ağlarının nöronlarında kullanılır ve nöronun çıktısını belirlemek için uygulanır. Aktivasyon fonksiyonlarının amacı, doğrusal olmayan ilişkileri modellemeye yardımcı olmaktır [35]. Çeşitli aktivasyon fonksiyonları kullanılabilir, bunlardan bazıları şunlardır:

- Sigmoid
- Hiperbolik Tanjant
- Düzeltilmiş Doğrusal Birim (ReLU)
- Sızdıran Düzeltilmiş Doğrusal Birim (Leaky ReLU)
- Softmax

Aktivasyon fonksiyonları, derin öğrenme modellerinin performansını ve öğrenme yeteneğini büyük ölçüde etkiler. Bu bölümde, ReLU, sigmoid, tanh, softmax ve Leaky ReLU gibi yaygın olarak kullanılan aktivasyon fonksiyonları incelenmiştir. Her aktivasyon fonksiyonunun avantajları ve dezavantajları bulunmakla birlikte, uygulamanın gereksinimlerine ve problem doğasına göre en uygun olanının seçilmesi önemlidir. Aktivasyon fonksiyonlarıyla ilgili daha fazla araştırma, daha iyi performans ve öğrenme süreçlerine katkı sağlayarak derin öğrenme alanındaki gelişmelere ışık tutmaya devam edecektir. [42]

Düzeltilmiş Doğrusal Birim Aktivasyon Fonksiyonu

Düzeltilmiş doğrusal birim aktivasyon fonksiyonu, derin öğrenme modellerinde en yaygın olarak kullanılan aktivasyon fonksiyonlarından biridir. Nair ve Hinton (2010) tarafından tanıtılmış olup, matematiksel olarak Eşitlik 2.13'te gösterildiği gibidir. Düzeltilmiş doğrusal birim aktivasyon fonksiyonu, özellikle derin sinir ağlarında popülerdir çünkü hesaplaması hızlıdır ve kaybolan gradyan problemine karşı daha dirençlidir [24]. Düzeltilmiş doğrusal birim aktivasyon fonksiyonu Şekil 2.2'de gösterilmiştir.

$$f(x) = \max(0, x) \quad (2.13)$$

Girdi x , pozitif olduğunda $f(x) = x$ olacak ve x negatif olduğunda $f(x) = 0$ olacaktır.




Şekil 2.2. Düzeltilmiş doğrusal birim aktivasyon fonksiyonu grafiği

Sigmoid Aktivasyon Fonksiyonu

Sigmoid aktivasyon fonksiyonu, daha eski yapay sinir ağlarında yaygın olarak kullanılan ve lojistik fonksiyon olarak da bilinen bir aktivasyon fonksiyonudur. Matematiksel olarak Eşitlik 2.14'te gösterildiği gibi tanımlanır. Sigmoid fonksiyonu, çıktı değerlerini 0 ile 1 arasında sınırlar ve böylece olasılık değerleri olarak yorumlanabilir. Bununla birlikte, sigmoid fonksiyonu kaybolan gradyan problemine eğilimli olduğu için derin ağlarda kullanımı sınırlıdır [36]. Sigmoid fonksiyonunun grafiği ise Şekil 2.3'te belirtilmiştir.

$$f(x) = \frac{1}{(1 + e^{-x})} \quad (2.14)$$




Şekil 2.3. Sigmoid aktivasyon fonksiyonu grafięi

Sigmoid fonksiyonunun grafięi, bir “S” şeklinde eęri olup, girdi deęerleri (x) negatif sonsuza yaklaştıkça 0’a ve girdi deęerleri pozitif sonsuza yaklaştıkça 1’e yaklařır.

Hiperbolik Tanjant Aktivasyon Fonksiyonu

Hiperbolik Tanjant aktivasyon fonksiyonu, sigmoid fonksiyonunun bir varyasyonudur ve -1 ile 1 arasında deęerler alır. Matematiksel olarak Eřitlik 2.15’te gősterildięi gibi tanımlanır. Hiperbolik Tanjant aktivasyon fonksiyonu, sigmoid fonksiyonuna gőre daha iyi performans gőstermesine raęmen, yine de derin aęlarda kaybolan gradyan problemi yařayabilir [23]. Hiperbolik tanjant aktivasyon fonksiyonunun grafik gősterimi ise Őekil 2.4’te gősterilmiřtir.

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (2.15)$$



Şekil 2.4. Hiperbolik tanjant grafięi

Softmax Aktivasyon Fonksiyonu

Softmax aktivasyon fonksiyonu, çok sınıflı sınıflandırma problemlerinde kullanılır ve her sınıf için olasılık dağılımı üretimi sağlar. Matematiksel olarak, Eşitlik 2.16'da gösterildiği şekilde tanımlanır.

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum(e^{x_j})} \quad (2.16)$$


Burada x , girdi vektörüdür ve j , sınıf etiketlerini temsil eder. Softmax fonksiyonu, genellikle sinir ağlarının çıktı katmanında kullanılır ve her sınıf için tahmini olasılıkları hesaplar [37].

Sızdıran Düzeltilmiş Doğrusal Birim Aktivasyon Fonksiyonu

Sızdıran düzeltilmiş doğrusal birim aktivasyon fonksiyonu, düzeltilmiş doğrusal birim aktivasyon fonksiyonunun bir çeşididir ve giriş değeri negatif olduğunda küçük bir değer döndürerek, ölü nöron problemine çözüm sunar. Sızdıran düzeltilmiş doğrusal birim aktivasyon fonksiyonu, matematiksel olarak Eşitlik 2.17'de gösterildiği şekilde tanımlanır, burada α genellikle 0.01 gibi küçük bir değerdir [38].

$$f(x) = \max(\alpha x, x) \quad (2.17)$$

Sızdıran düzeltilmiş doğrusal birim aktivasyon fonksiyonu, $x > 0$ olduğunda doğrusal olarak artar ve $x < 0$ olduğunda doğrusal olarak azalır. Bu sayede, aktivasyon fonksiyonu tamamen sıfır olmayan bir türevelere sahip olur ve öğrenme sürecini iyileştirir. Şekil 2.5'te sızdıran düzeltilmiş doğrusal birim aktivasyon fonksiyonunun grafiği gösterilmektedir.



Şekil 2.5. Sızdıran düzeltilmiş doğrusal birim aktivasyon fonksiyonu grafiği

2.5. Hiper Parametreler

Parametreler ve hiperparametreler, makine öğrenmesi ve derin öğrenme modellerinin iki önemli bileşenidir, ancak farklı şekillerde işlev görürler. Parametreler, modelin eğitim süreci boyunca öğrendiği ve sürekli olarak ayarladığı değerlerdir. Buna örnek olarak bir sinir ağının ağırlıkları ve yanlılıkları verilebilir. Bu değerler, modelin öğrenme yeteneğini ve tahminlerin doğruluğunu belirler. Hiper parametreler, modelin eğitim öncesi belirlenen ve eğitim sürecini yönlendiren değerlerdir. Bunlara örnek olarak, öğrenme hızı, yığın büyüklüğü, faz sayısı ve ağ yapısı gibi değerler verilebilir. Hiper parametreler, ağın mimarisi, öğrenme oranı, aktivasyon fonksiyonları ve optimizasyon teknikleri gibi alanlarda ayarlamalar yaparak, ağın performansının iyileştirilmesine katkıda bulunur [39].

Katman Sayısı ve Nöron Sayısı

Katman sayısı ve her katmandaki nöron sayısı, sinir ağı modellerinin en önemli hiper parametrelerindendir. Katman sayısı, modelin karmaşıklığını ve öğrenebileceği özelliklerin hiyerarşisini belirler [40]. Nöron sayısı, her bir katmanda modelin öğrenebileceği özelliklerin sayısını belirler. Bu hiper parametrelerin doğru seçimi, modelin öğrenme kapasitesi ve genelleştirme performansı üzerinde büyük etkiye sahiptir [41].

Öğrenme Oranı

Öğrenme oranı, modelin ağırlıklarını güncellerken ne kadar hızlı değişiklik yapacağını belirleyen bir hiper parametredir. Büyük öğrenme oranları hızlı öğrenmeye yol açarken, küçük öğrenme oranları daha yavaş ve daha doğru öğrenmeye imkan tanımaktadır.

Düzenleştirme Parametreleri

Düzenleştirme teknikleri, aşırı uyum (overfitting) problemini azaltarak modelin genelleştirme kabiliyetini artırır. Evrişimli sinir ağlarında yaygın olarak kullanılan düzenleştirme teknikleri arasında sönümlenme (dropout), L1 ve L2 düzenlendirmesi bulunmaktadır [27].

L1 ve L2 düzenlendirme gibi düzenlendirme yöntemlerinin seçimi ve ilgili parametreler, modelin genelleştirme performansını etkiler [43]. Düzenlendirme parametreleri, modelin


karmaşıklığını sınırlayarak ve ağırlıkları küçük tutarak aşırı uyumu önlemeye yardımcı olur [21].

2.6. Derin Öğrenme Tabanlı Görüntü Sınıflandırma

Derin öğrenme modelleri, görüntü sınıflandırması için katmanlı yapıları ve karmaşık öğrenme süreçlerini kullanarak, etkili ve doğru tahminlerde bulunabilirler [24]. Tezinde konusu olan beyin tümörü sınıflandırması için kullanılacak derin öğrenme tabanlı modeller, özelliklerin otomatik öğrenilmesini sağlayarak, tümör tipi ve konumunun tahmin edilmesinde yüksek doğruluk elde etmeyi amaçlar.

Evrışimli Sinir Ağları

Evrışimli sinir ağları, derin öğrenme alanında başarılı bir şekilde kullanılan ve özellikle görüntü sınıflandırma, nesne tanıma ve doğal dil işleme gibi alanlarda etkileyici sonuçlar elde eden yapay sinir ağlarıdır (Şekil 2.6). Yapay zekâ ve öğrenme sistemlerinde ilhamını biyolojik sinir ağlarından alan evrişimli sinir ağları, özellikle görüntü verilerini işleme kabiliyetleri ile öne çıkmaktadır [23]. Bu tez bölümünde, evrişimli sinir ağlarının temel bileşenleri ve çalışma prensipleri incelenerek, bu teknolojinin güçlü yönleri ve potansiyel uygulamaları hakkında bir genel bakış sunulacaktır.




Şekil 2.6. Yapay sinir ağları çalışma mantığı

Evrışim Katmanı

Evrışim katmanı, girdi verisine (örneğin bir görüntü) bir filtre (kernel) uygulayarak yerel özellikleri öğrenir ve bu sayede öğrenme sürecini daha verimli hale getirir [24]. Filtreler, özellik haritalarını oluşturmak için girdi verisi üzerinde kaydırılır ve bu süreç sonunda, ağ öğrenilmiş özelliklerle daha karmaşık görevleri gerçekleştirebilir hale gelir [23].

Evrişimli sinir ağlarının başarısı, özellikle biyolojik görsel algı sistemlerine benzer hiyerarşik yapıları sayesinde elde edilmektedir [23]. Bu yapı, düşük seviyeli özelliklerden yüksek seviyeli özelliklere doğru katmanlar arası bilgi aktarımını mümkün kılar ve bu sayede karmaşık görsel problemleri çözme kapasitesini artırır. Evrişimli sinir ağlarının başarısı, ImageNet Large Scale Visual Recognition Challenge (ILSVRC) gibi yarışmalarda elde ettikleri üstün sonuçlarla kanıtlanmıştır [28]. Bir görüntü üzerinden evrişimli yapay sinir ağı örneği Şekil 2.7’de gösterilmiştir.



Şekil 2.7. Evrişimli yapay sinir ağı çalışma örneği

Ortaklama Katmanı

Ortaklama (pooling) katmanı, girdi verisinin boyutunu küçültmeye ve ağın hesaplama yükünü azaltmaya yardımcı olur. En yaygın kullanılan ortaklama yöntemleri maksimum ortaklama ve ortalama ortaklamadır [26].

Maksimum Ortaklama

Maksimum ortaklama, girdi matrisinin belirli bir pencere boyutu ve adım boyutu (stride) kullanarak işlenmesidir. Pencerenin her konumunda, bu penceredeki maksimum değer alınır ve çıktı matrisine yerleştirilir. Maksimum ortaklama, önemli öznitelikleri koruyarak matrisin boyutunu küçültmeye yardımcı olur. Maksimum ortaklamanın temel avantajı, yerel maksimumları kullanarak en belirgin özellikleri korumasıdır. Şekil 2.8’de maksimum ortaklamaya ilişkin örnek görsel paylaşılmıştır.



Şekil 2.8. Maksimum ortaklama gösterimi

Ortalama Ortaklama

Ortalama ortaklama, maksimum ortaklama ile benzer şekilde çalışır, ancak pencerenin her konumunda ortalamayı alarak çıktı matrisini oluşturur. Bu işlem, girdi matrisinin boyutunu küçültürken daha yumuşak bir öznitelik düşürme imkanı sağlar. Ortalama ortaklama, girdi matrisindeki bilgiyi daha düşük çözünürlüklü bir temsile yayarak korumaya çalışır. Şekil 2.9'da ortalama ortaklama için örnek görsel paylaşılmıştır.



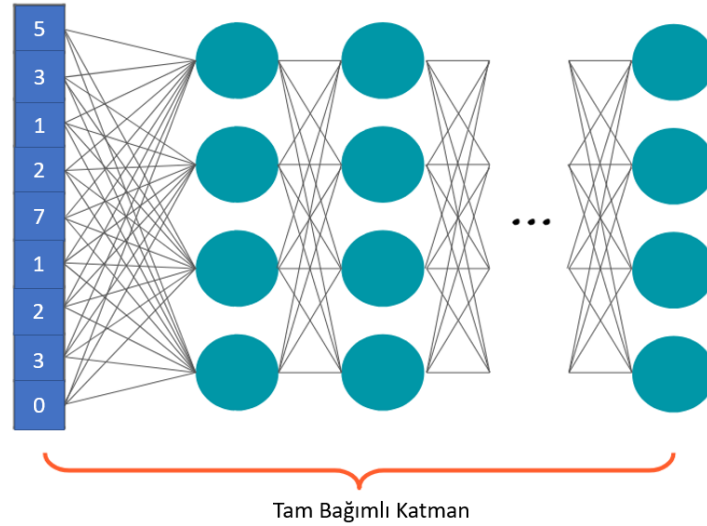
Şekil 2.9. Ortalama ortaklama gösterimi

Tam Bağlantılı Katmanı

Evrışimli sinir ağlarının sonunda yer alan tam bağlantılı katmanlar, öğrenilen özellikleri kullanarak nihai sınıflandırma veya regresyon problemini çözmeye yönelik sonuçlar üretir [24]. Tam bağlantılı katmanlar, sınıflandırma problemlerinde çıktı katmanında kullanılır ve Softmax aktivasyon fonksiyonu ile birleştirilir. Softmax, her sınıf için olasılık dağılımını sağlar ve sınıf etiketlerine dönüştürmek için en yüksek olasılığa sahip sınıfı seçer.

Özetle, tam bağlantılı katman, öğrenilen öznitelikleri bir öğrenme görevine (sınıflandırma, regresyon vb.) uygulamak için kullanılır. Tüm nöronların birbiriyle

bağlantılı olduğu bu katmanda, ağırlıklı toplamlar hesaplanır, aktivasyon fonksiyonları uygulanır ve problem tipine göre çıktı değerleri elde edilir. Tam bağlantılı katmanın yapısı Şekil 2.10'da belirtilmiştir.



Şekil 2.10. Tam bağlantılı katman örneği

Öğrenme Aktarımı ve Önceden Eğitilmiş Modeller

Öğrenme aktarımı, önceden eğitilmiş derin öğrenme modellerinin, yeni ve benzer problemler için kullanılmasına olanak tanır [45]. Önceden eğitilmiş modeller, genellikle büyük ve genel veri kümeleri üzerinde eğitilmiş olup, bu sayede elde edilen bilgi ve özellikler, yeni problemlere uygulanarak zaman ve hesaplama kaynaklarından tasarruf sağlar.

Beyin tümörü sınıflandırması için kullanılacak öğrenme aktarımı yöntemleri, önceden eğitilmiş evrişimli yapay sinir ağı modellerini (örneğin, EfficientNet, ResNet, Inception) beyin tümörü görüntü veri kümesi üzerinde parametre değişimleri sağlanarak kullanabilir. Bu işlem, önceden eğitilmiş ağın son katmanlarının, yeni veri kümesine göre eğitilmesi ve güncellenmesi işlemidir. [46]

Öğrenme aktarımı, özellikle küçük veri kümeleri için önemlidir, çünkü önceden eğitilmiş modellerin öğrenilmiş özellikleri, yeni problemlerde daha hızlı ve etkili sonuçlar elde etmeye yardımcı olur. Beyin tümörü sınıflandırması için önceden eğitilmiş modellerin

kullanılması, öğrenme sürecini hızlandırabilir ve daha doğru sonuçlar elde etmeye olanak tanır.

Bu tezde, beyin tümörü sınıflandırması için kullanılacak derin öğrenme tabanlı yöntemler ile evrişimli yapay sinir ağı modelleri yanında öğrenme aktarımı tekniklerinin incelenmesi ve uygulanması üzerinde durulacaktır. Ayrıca, bu yöntemlerin sınıflandırma performansı ve etkinliği, farklı model ve hiper parametre kombinasyonları kullanılarak değerlendirilecektir.

3. GÖRÜNTÜ VERİLERİNİN ÖN İŞLEME SÜREÇLERİ VE SINIFLANDIRMA MODELLERİNİN GELİŞTİRİLMESİ

Görüntüleme verilerinin ön işleme, beyin tümörü sınıflandırması için kullanılacak derin öğrenme modellerinin eğitimi ve doğruluğu açısından önemlidir. Bu bölümde, görüntü verilerinin toplanması, ön işleme teknikleri ve veri artırma yöntemlerine değinilecektir. Aynı zamanda, beyin tümörü sınıflandırması için kullanılacak derin öğrenme tabanlı modellerin geliştirilmesi sürecine odaklanılacaktır. Kullanılan evrişimli yapay sinir ağı mimarileri ve varyasyonları, eğitim, değerlendirme, test veri kümeleri ve model performans metrikleri ele alınacaktır.

3.1. Görüntü Verilerinin Toplanması ve Kaynakları

Beyin tümörü sınıflandırması için kullanılacak görüntü verileri, genellikle manyetik rezonans görüntüleme (MRI) ve bilgisayarlı tomografi (CT) gibi tıbbi görüntüleme tekniklerinden elde edilir [47]. Görüntü verileri, hastaneler, araştırma merkezleri ve kamuya açık veri kümeleri gibi kaynaklardan toplanabilir. Özellikle, Multimodal Brain Tumor Image Segmentation Benchmark (BRATS) gibi kamuya açık veri kümeleri, beyin tümörü sınıflandırması için kullanılacak verilerin elde edilmesinde önemli bir kaynaktır [47].

Tez kapsamında farklı veri kümeleri farklı tekniklerle denenerek kapsamlı bir karşılaştırmaya tabii tutulmuştur.

3.2. Görüntü Ön İşleme Teknikleri

Görüntü ön işleme teknikleri, görüntü verilerini derin öğrenme modellerine uygun hale getirmek ve görüntü kalitesini artırmak için kullanılır [48]. Beyin tümörü sınıflandırması için kullanılacak ön işleme teknikleri şunları içerebilir:

- Gri tonlamalı dönüşüm
- Histogram eşitleme
- Gürültü azaltma
- Görüntü normalleştirme

Gri Tonlamalı Dönüşüm

Renkli görüntülerin gri tonlamalı hale dönüştürülmesi, renk bilgilerinin önemli olmadığı veya hesaplamaları hızlandırmak için renk bilgisini kaldırmak istendiği durumlarda kullanılır. Gri tonlamalı dönüşüm, Kırmızı Yeşil Mavi (RGB) renk uzayındaki her pikselin bileşenlerini tek bir gri değere dönüştürerek gerçekleştirilir [49]. Konu ile alakalı örnek Eşitlik 3.1’de verilmiştir.

$$gri = 0.2989 * R + 0.6798 * G + 0.1998 * B \quad (3.1)$$

Burada eşitliğin sol tarafı, gri tonlamalı değeri temsil ederken, R, G ve B, sırasıyla kırmızı, yeşil ve mavi bileşenleri temsil eder. Bu ağırlıklandırma değerleri, insan gözünün yeşil ve kırmızıya maviye göre daha hassas olduğu gerçeğini yansıtır.

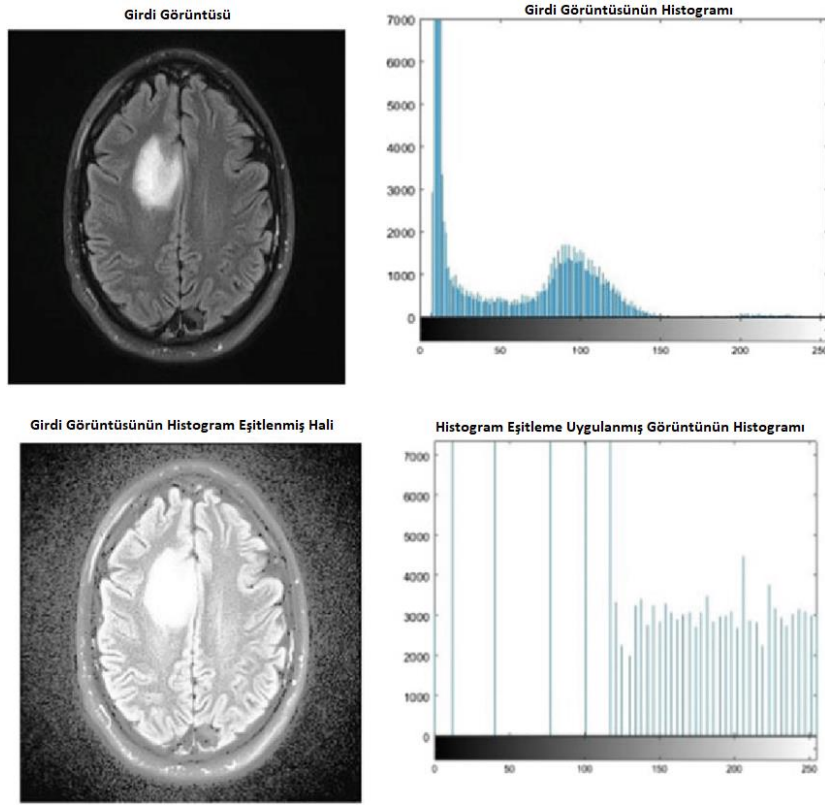
Gri tonlamalı dönüşüm, görüntü işleme ve bilgisayarlı görü uygulamalarında ön işleme adımı olarak yaygın olarak kullanılır. Bu dönüşüm, sadece gri tonlamalı değerlere odaklanarak algoritmanın karmaşıklığını ve hesaplama süresini azaltmaya yardımcı olur. Ayrıca, renkli görüntülerde gürültüyü azaltmaya ve kenar tespiti gibi bazı işlemlerin daha kolay gerçekleştirilmesini sağlar. Gri tonlamalı dönüşüm (Şekil 3.1), Optik Karakter Tanıma (OCR), yüz tanıma ve nesne tespiti gibi uygulamalar için kullanışlıdır.



Şekil 3.1. Gri tonlamalı örneği

Histogram Eşitleme


Histogram eşitleme, görüntüdeki kontrastı artırmak için kullanılır. Bu teknik, görüntünün histogramını eşit bir şekilde dağıtarak, gri seviyelerinin geniş bir aralıkta daha iyi temsil edilmesini sağlar [50]. Şekil 3.2’de bir beyin tümörünün MRI görüntüsüne uygulanan histogram eşitleme verilmiştir.



Şekil 3.2. Beyin tümörü görselinde Histogram Eşitleme

Gürültü Azaltma

Görüntülerdeki gürültü, özellikle düşük ışık koşullarında, sensörlerin sıcaklık değişimlerinden veya diğer faktörlerden kaynaklanabilir. Gürültü azaltma teknikleri, görüntüdeki istenmeyen piksel değerlerini düzeltmeye çalışır. Gürültü azaltma için kullanılan yaygın yöntemler arasında Gauss Bulanıklığı, Medyan Filtreleme ve Bilateral Filtreleme bulunmaktadır [51]. Şekil 3.3'te medyan filtreleme örneği verilmiştir.



Şekil 3.3. Görüntü matrisinde medyan filtreleme örneği

Görüntü Normalleştirme

Görüntü normalleştirme, görüntülerin piksel değerlerini ortak bir ölçeğe getirmek için kullanılır. Normalleştirme, derin öğrenme modelinin daha hızlı ve daha iyi bir şekilde eğitilmesine yardımcı olur. Görüntü normalleştirme yöntemleri arasında minimum-maksimum normalleştirme, Z-skor normalleştirme ve görüntü beyazlatma bulunmaktadır [52].

Veri Artırma Yöntemleri

Veri artırma yöntemleri, eğitim veri kümesinin çeşitliliğini ve boyutunu artırarak, derin öğrenme modellerinin daha iyi genelleştirme performansı sergilemesine yardımcı olan bir yöntemdir [53]. Veri artırma, özellikle küçük veri kümeleri için önemlidir, çünkü modellerin aşırı uyum riskini azaltmaya yardımcı olur. Beyin tümörü sınıflandırması için kullanılacak veri artırma yöntemleri şunları içerebilir:

- Döndürme: Görüntülerin belirli bir açıda döndürülerek yeni görüntüler elde edilmesi.
- Ölçeklendirme: Görüntülerin farklı oranlarda büyütülmesi veya küçültülmesi.
- Çevirme: Görüntülerin yatay veya dikey ekseninde çevrilerek yeni görüntüler oluşturma.
- Kesme: Görüntülerin belirli bir alanda kesilerek yeni görüntüler elde etme.
- Parazit ekleme: Görüntülere küçük miktarda rastgele gürültü ekleyerek yeni görüntüler oluşturma.

Veri artırma yöntemleri, eğitim sürecinde kullanılan verilerin çeşitliliğini artırarak, derin öğrenme modellerinin gerçek dünya verilerine daha iyi uyum sağlamasına ve başarı oranını artırmasına katkıda bulunur.

Bu tezde, beyin tümörü sınıflandırması için kullanılacak görüntüleme verilerinin toplanması, ön işleme teknikleri ve veri artırma yöntemleri üzerinde durulacaktır. Ayrıca, bu yöntemlerin sınıflandırma performansı ve etkinliği, farklı ön işleme ve veri artırma kombinasyonları kullanılarak değerlendirilecektir.

Derin Öğrenme Tabanlı Bölütlenme

Derin öğrenme tabanlı bölütlenme yöntemleri, özellikle evrişimli sinir ağları kullanarak görüntüden karmaşık özellikler öğrenir ve bu özelliklere göre bölütlenme gerçekleştirir. Derin öğrenme tabanlı yöntemler, özellikle tıbbi görüntü analizi ve uydu görüntü analizi gibi zorlu ve karmaşık alanlarda etkili sonuçlar sağlamaktadır. UNet ve Mask R-CNN gibi popüler derin öğrenme mimarileri, başarılı bölütlenme için kullanılır [53].

3.3. Model Performans Metrikleri ve Değerlendirme

Derin öğrenme tabanlı sınıflandırma modellerinin performansını değerlendirmek için kullanılacak metrikler arasında doğruluk, hassasiyet, duyarlılık ve F1 puanı bulunmaktadır [55]. Bu metrikler, modellerin sınıflandırma başarısı ve hatalarını değerlendirmede kullanılmaktadır.

Modellerin performansını değerlendirmek ve optimize etmek için kullanılan yöntemler, sınıflandırma doğruluğunu ve genel model performansını artırmayı hedeflemektedir.

Doğruluk

"Doğruluk, genellikle sınıflandırma görevlerinin en çok kullanılan metriğidir ve doğru sınıflandırılan örneklerin toplam örnek sayısına oranı olarak tanımlanır." [58] Doğruluğun denklemi Eşitlik 3.2'de verilmiştir.

$$\text{Doğruluk} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (3.2)$$

Bu eşitlikte:

- TP: Gerçek pozitif örneklerin doğru bir şekilde pozitif olarak sınıflandırılması.
- TN: Gerçek negatif örneklerin doğru bir şekilde negatif olarak sınıflandırılması.
- FP: Gerçek negatif örneklerin yanlış bir şekilde pozitif olarak sınıflandırılması.
- FN: Gerçek pozitif örneklerin yanlış bir şekilde negatif olarak sınıflandırılması.

Hassasiyet

"Hassasiyet, modelin pozitif olarak sınıflandırdığı tüm örnekler arasında gerçekten pozitif olan örneklerin oranını temsil eder." [59] Denklemi Eşitlik 3.3'te verilmiştir.

$$\text{Hassasiyet} = \frac{TP}{TP + FP} \quad (3.3)$$

Duyarlılık

"Duyarlılık, gerçekten pozitif olan tüm örnekler arasında modelin doğru bir şekilde pozitif olarak sınıflandırdığı örneklerin oranını gösterir." [59] Denklemi Eşitlik 3.4'te verilmiştir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3.4)$$

F1 Puanı

"F1 Puanı, hassasiyet ve duyarlılık metriklerinin harmonik ortalamasıdır ve genellikle dengesiz veri setleri için kullanılır. F1 Puanı, hassasiyet ve duyarlılığı dengeli bir şekilde birleştirir." [60] Denklemi Eşitlik 3.5'te verilmiştir.


$$\text{F1 Skor} = \frac{2 \times (\text{Hassasiyet} \times \text{Duyarlılık})}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (3.5)$$

4. UYGULAMA

4.1. Veri Setleri ve Problem Tanımı


Bu tez çalışmasında, otomatik beyin tümörü tespiti ve sınıflandırılması problemi ele alınmaktadır. Tıbbi görüntü analizinde yaygın bir uygulama alanı olan bu problem, beyin tümörlerinin tespiti ve sınıflandırılmasında otomatik ve etkin yöntemlerin geliştirilmesi ihtiyacından doğmaktadır.

Tez kapsamında, figshare, SARTAJ ve Br35H veri kümeleri üzerinde bulunan iki ayrı veri seti kullanılmıştır: "Brain Tumor Classification (MRI) " ve "Brain Tumor MRI Images 44-Classes Dataset". İlk veri seti, dört farklı türdeki beyin tümörünün MRI görüntülerini içerirken, ikinci veri seti 44 farklı türdeki beyin tümörlerinin görüntülerini kapsar. Her bir veri seti, modelin eğitimi ve performans değerlendirmesi için eğitim ve değerlendirme seti olmak üzere iki alt kümeye ayrılmıştır. 4 sınıflı veri setine ait rastgele görüntüler şekil 4.1'de, 44 sınıflı veri setine ait rastgele görüntüler ise şekil 4.2'de gösterilmektedir.



Şekil 4.1 Dört sınıflı veri setine ait örnek görseller

4 sınıflı veri seti için tanımlanan sınıflar şu şekildedir. Pituitary, meningioma ve glioma birer tümör tipidir. Notumor sınıfı ise tümör bulunmayan MRI görüntülerini içermektedir.



Şekil 4.2. Kırk dört sınıflı veri setine ait örnek görseller

44 sınıflı veri seti için tümör tipleri T1, kontrastlı T1 ve T2 görüntülerinden oluşmaktadır. Tümör ana sınıfları ise astrocytoma, carcinoma, ependymoma, ganglioglioma, germinoma, glioblastoma, granuloma, medulloblastoma, meningioma, neurocytoma, oligodendroglioma, papilloma, schwannoma ve tuberculoma şeklindedir.

Tez çalışması süresince, görüntü ön işleme ve öğrenme aktarımı gibi görüntü işleme ve derin öğrenme teknikleri kullanılmıştır. Görüntü ön işleme süreci, MRI görüntülerini modelin daha kolay anlayabileceği bir forma dönüştürmeyi amaçlar.

Öğrenme aktarımı yöntemi ise, büyük veri setleri üzerinde önceden eğitilmiş olan modellerin ağırlıklarını kullanarak, model eğitim süresini kısaltmayı ve genellikle daha yüksek performans elde etmeyi hedefler. ImageNet veri seti, insanlar tarafından oluşturulmuş 14 milyondan fazla görüntüyü ve tanımını içeren büyük bir veri setidir. Bu veri seti ile eğitilen algoritmalar belirli ağırlık değerlerine sahip olur. Bu sayede öğrenme

aktarımını özelleştirilmiş bir veri seti üzerinde eğitmek hem daha hızlı hem de daha doğru sonuçlar vermektedir.

Çalışma kapsamında öğrenme aktarımı algoritmalarında “ImageNet” ağırlıkları ile eğitilen algoritmalar kullanılmıştır. Ayrıca öğrenme aktarımı algoritmalarının “ImageNet” ağırlıklarıyla eğitilmemiş versiyonları, aynı mimariye sahip algoritmaların sonuçlarında nasıl bir değişim olduğunu da göstermeyi amaçlamaktadır.


Bu çerçevede, modelin eğitim sürecinde kullanılan veri setlerinin geniş bir tümör çeşitliliği içermesi ve bu tümörlerin genel ve özelleşmiş özelliklerinin öğrenilmesi hedeflenmiştir. Modelin 4 sınıflı veri setindeki performansının değerlendirilmesi ise, daha önce hiç görmediği test kümeleri üzerinde yapılmıştır. Bu değerlendirme, modelin genelleme yeteneğinin ve gerçek dünya durumlarına uygulanabilirliğinin test edilmesi amacıyla yapılır. Ancak 44 sınıflı veri setinin sınıf fazlalığı ve bazı sınıflarda az bulunan görüntüler nedeniyle test kümesi ayırımına gidilmemiş, değerlendirme seti ile sınıflandırma sonuçları elde edilmiştir. Her bir sınıfın yüksek doğruluk oranıyla eğitilmesi amaçlanmıştır.

4 sınıflı veri seti için eğitim bilgileri tabloda verilmiştir.

Çizelge 4.1. 4 sınıflı veri seti için eğitim bilgileri

Tümör Tipi	Eğitim Kümesi	Değerlendirme Kümesi	Test Kümesi	Toplam
Gliom	674	164	88	926
Meningeom	670	171	96	937
Pituitary	668	169	64	901
Tümör Yok	362	90	48	500

44 sınıflı veri seti için eğitim bilgileri tabloya sığmadığı için Şekil 4.3'te verilmiştir.



Şekil 4.3. 44 sınıflı veri seti için eğitim bilgileri

Sonuç olarak, bu tez çalışması, beyin tümörlerinin otomatik tespiti ve sınıflandırılması problemine odaklanmış ve bu problemi çözmek için kullanılan tekniklerin ve yaklaşımların etkinliğini iki farklı veri seti üzerinde değerlendirmiştir. Elde edilen bulguların, bu alanda gelecekte yapılacak çalışmalara yol gösterici olması ve beyin tümörü teşhisi ve tedavisi alanında kullanılan teknolojilerin geliştirilmesine yardımcı olması beklenmektedir.


4.2. Kullanılan Ön İşleme Yöntemleri

Görüntü Normalleştirme

Bu kısımda tüm piksel değerleri 0 ile 1 arasında olacak şekilde yeniden ölçeklendirilir. Bu işlem, görüntü kontrastını optimize etmeye ve model eğitimi sırasında hesaplamaları hızlandırmaya yardımcı olur.

Veri Arttırma

Bu kısımda veri kümesinin çeşitliliğini artırmak ve modelin genelleştirme yeteneğini iyileştirmek için çeşitli görüntü dönüşümleri uygulanır. Burada döndürmek, ölçeklendirme, döşeme, yansıtma ve kontrast ayarlama tüm modeller için uygulanmıştır. Uygulanan dönüşümlerin ve veri arttırma işlemlerinin bir örnek ile temsili Şekil 4.4'teki gibidir.



Şekil 4.4. Uygulanan veri arttırma ve dönüştürme yöntemleri örnek görseli

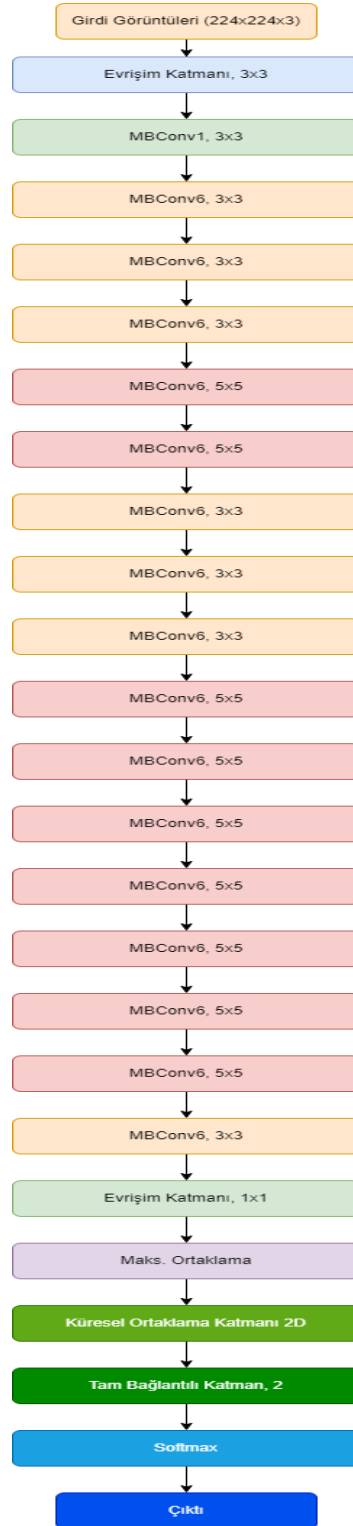
Görüntü Boyutlarını Yeniden Ölçeklendirme

Bu kısımda farklı boyutlardaki görüntüler, modelin girdi katmanına uygun olacak şekilde yeniden boyutlandırılmıştır. Tüm görüntüler 224x224 piksel boyutlarına getirilmiştir. Bu modelin eğitim hızını arttıracak gibi optimal bir geliştirme performansı sağlaması hedeflenmiştir.

4.3. Kullanılan Teknik Yöntemler ve Mimariler

Önceden eğitilmiş modellerin kullanımı, öğrenme aktarımı sürecinin temel bileşenidir. Beyin tümörü sınıflandırması için en uygun modeli seçmek bu tez için önemlidir. Bu çalışmada, EfficientNet, ResNet, DenseNet, MobileNet ve Inceptionv4 gibi önceden eğitilmiş modeller incelenmiş ve performanslarını karşılaştırarak en uygun model seçilmiştir. Ayrıca öğrenme aktarımı yaklaşımının gücünü göstermek adına yukarıda bazı ağ mimarileri “ImageNet” ağırlıkları olmadan eğitilmiştir. Ağırlıkları 0 noktasından başlatmak, önceden eğitilmiş ağırlıklar üzerine öğrenen modeller ile performans karşılaştırması yapmak adına önemlidir. Seçilen modelleri yeni görevimize uyarlamak için, modelin çıktı katmanını değiştirerek, sınıflandırma problemimize uygun hale getirilmiştir. Bu, özellikle son katmanda yapılan değişikliklerle gerçekleştirilmektedir.

4.3.1. EfficientNet Mimarisi



Şekil 4.5. EfficientNet Mimarisi

Şekil 4.5'te, EfficientNet mimarisinin farklı bileşenleri ve ölçeklendirme faktörlerinin nasıl uygulandığı görülmektedir. Görüldüğü gibi, giriş görüntüsü ilk olarak bir başlangıç evrişim katmanından geçer. Ardından, Mobil ters darboğaz evrişim (Mobile Inverted Bottleneck Convolution - MBConv) blokları içeren bir dizi özellik çıkarma modülü takip eder. Bu modüller, özelliklerin daha karmaşık ve soyut temsillerini öğrenirken, modelin hesaplama verimliliğini ve performansını optimize etmeye yardımcı olur.

Her MBConv bloğunun ardından, özellik haritaları birleştirilir ve ortaklama katmanına uygulanır. Bu, her özellik haritasının küresel ortalamasını alarak, daha düşük boyutlu bir vektöre dönüştürür. Ortaklama katmanından sonra, bir tam bağlantılı katman kullanılarak son sınıflandırma gerçekleştirilir ve sonuç, aktivasyon fonksiyonu ile normalize edilir.

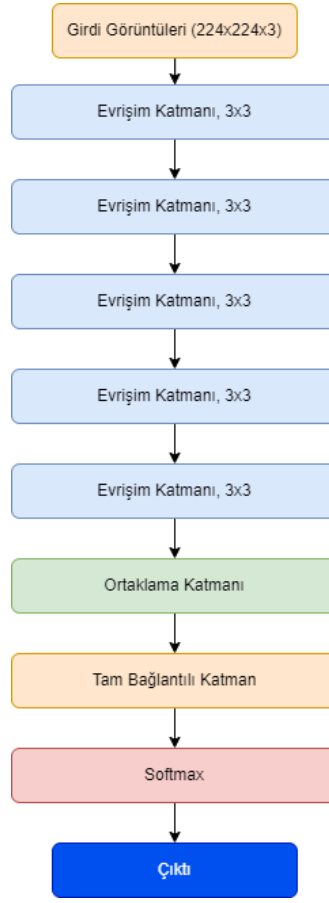
EfficientNet mimarisi, daha az hesaplama gücü ve parametre kullanarak yüksek doğruluk sağlaması nedeniyle, sınıflandırma problemleri için popüler olarak tercih edilir. Beyin tümörü sınıflandırması gibi görevlerde, EfficientNet kullanarak daha hızlı ve doğru sonuçlar elde edilebilir.

4.3.2. ResNet Mimarisi

ResNet mimarisi, 2015 yılında He ve arkadaşları tarafından geliştirilmiştir. Bu mimari, derin öğrenme alanında önemli bir ilerleme sağlamıştır ve kaybolan gradyan (vanishing gradient) sorununu hafifletmek amacıyla tasarlanmıştır. ResNet, "artıklar" adı verilen kısa bağlantılar kullanarak, daha önceki katmanların çıktılarını daha sonraki katmanlara doğrudan ekler [53]. Bu sayede, gradyanların daha derin katmanlara etkin bir şekilde geri yayılması sağlanır.

ResNet mimarisi, ardışık evrişim katmanları ve kısa bağlantılar içeren artık bloklardan oluşur. Daha derin ResNet mimarilerinde, hesaplama verimliliğini artırmak için "dar boğaz" (bottleneck) adı verilen blok yapısı kullanılır [53]. Dar boğaz bloklar, genişlik ve derinlik boyutlarını sırasıyla azaltarak ve artırarak, modelin daha az parametre ile daha hızlı öğrenmesine olanak tanır.

Şekil 4.6, ResNet mimarisinin temel yapı taşlarını göstermektedir:



Şekil 4.6. ResNet Mimarisi

ResNet'te, özellik haritaları artık blokların çıkışında birleştirilir ve ortaklama katmanına uygulanır. Bu, her özellik haritasının küresel ortalamasını alarak, daha düşük boyutlu bir vektöre dönüştürür. Ortaklama katmanından sonra, bir tam bağlantılı katman kullanılarak son sınıflandırma gerçekleştirilir ve sonuç, aktivasyon fonksiyonu softmax ile normalize edilir.

ResNet mimarisi, doğrusal olmayan katman sayısının arttıkça performansın doyuma ulaştığı ve hatta azaldığı gözlemlenmiş olan geleneksel evrişimsel yapay sinir ağlarından farklı olarak, daha derin ağlarla bile yüksek doğruluk sağlamaktadır [53]. Bu, ResNet'in özellikle derin sinir ağları için önemli bir tercih sebebidir.

Beyin tümörü sınıflandırması gibi görevlerde, ResNet kullanarak daha hızlı ve doğru sonuçlar elde edilebilir. ResNet'in kaybolan gradyan sorununu hafifleten özelliği

sayesinde, daha derin ve daha güçlü modellerle çalışmak mümkün hale gelmiştir, bu da daha zorlu sınıflandırma problemleri için önemli avantajlar sunmaktadır.


4.3.3. DenseNet Mimarisi

DenseNet, derin öğrenme modellerinde büyük bir ilerleme olan bir mimaridir. Bu model, Evrişimli Sinir Ağı tasarımının evrimini temsil eder ve ağırlıklı olarak görsel tanıma görevlerinde kullanılır. Mimarinin temelini, özelliklerin sürekli birleşimine dayalı bir yaklaşım oluşturur.

DenseNet mimarisinin temel fikri, her katmandan çıkan özellik vektörlerinin, sadece bir sonraki katmana değil, tüm sonraki katmanlarına doğrudan bağlanmasıdır. Bu, "Yoğun Bloklar" adı verilen bir yapı ile sağlanır. Bu yapı, özelliklerin yeniden kullanılmasını ve ağ boyunca bilgi akışının korunmasını sağlar.

"DenseNet, doğrudan yollar sayesinde bilginin ve gradyanların ağı derinliklerine kolayca akmasını sağlar. Bu, bilgiyi kaybetmeden veya bozulmadan ağ boyunca aktarmanın bir yolu olarak görülür." [55]

Ayrıca, DenseNet'in bir diğer önemli özelliği de parametre verimliliğidir. Doğrudan bağlantılar, katmanlar arasında özelliklerin daha etkin bir şekilde paylaşılmasına olanak sağlar ve bu da daha az parametre kullanımına yol açar. Bu, aynı zamanda modelin aşırı uyum riskini azaltır. DenseNet mimarisine ilişkin yapı Şekil 4.7'de paylaşılmıştır.



Şekil 4.7. DenseNet Mimarisi

1 numara ile ifade edilen kısım, yığın normalleştirme, ReLU ve evrişim katmanlarını içermektedir. 2 numara ile ifade edilen kısım ise aktarım katmanını temsil etmektedir.

Sonuç olarak, DenseNet, birçok derin öğrenme uygulamasında etkileyici sonuçlar elde etmiş olan ve özellikle görüntü sınıflandırma görevlerinde etkili olan ileri düzey bir mimardır. Bilgi akışının ve özelliklerin yeniden kullanılmasının öncelikli olduğu bu mimari, aynı zamanda parametre kullanımında etkilidir ve bu özellikleri nedeniyle popüler bir seçim olmuştur.

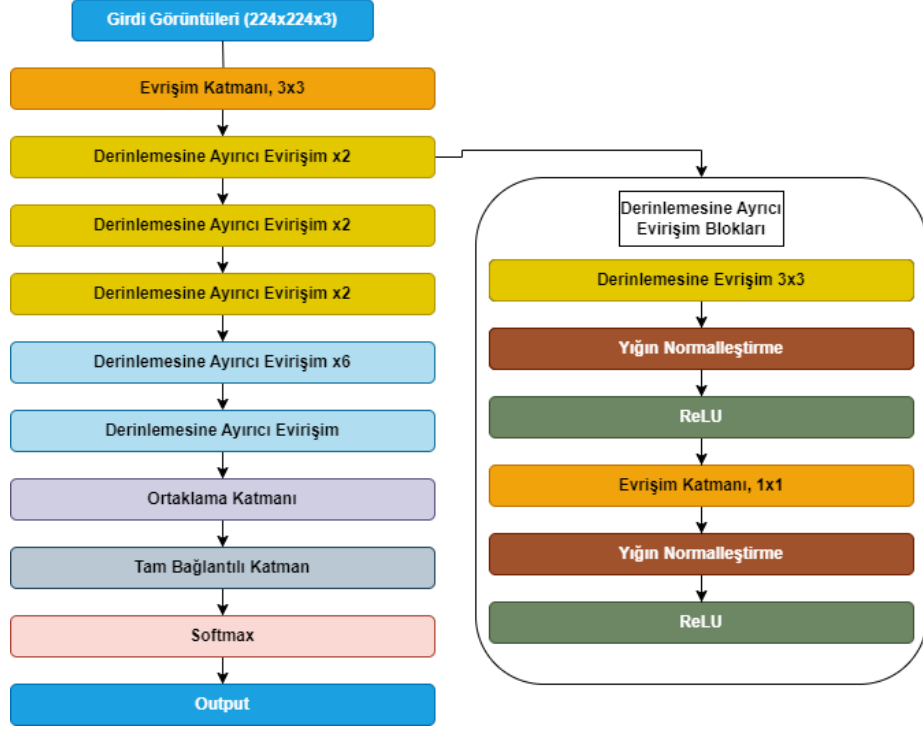
4.3.4. MobileNet Mimarisi

MobileNet, derin öğrenme topluluğunda önemli bir yer edinen bir sinir ağı mimarisi türüdür. Google tarafından geliştirilen bu mimari, genellikle kaynak sınırlı cihazlar olan mobil ve yerleşik sistemlerde kullanılmak üzere tasarlanmıştır. MobileNet, hafif bir yapıya sahip olmasına rağmen yüksek performanslı çıktılar üretebilir ve bu nedenle çok sayıda uygulamada kullanılır.

MobileNet'in temelinde, daha düşük hesaplama maliyetiyle birlikte kabul edilebilir düzeyde doğruluk sağlayan derinlemesine ayırıcı evrişimler yer alır. Bu, hem modelin boyutunu hem de karmaşıklığını azaltır ve daha hızlı daha verimli bir hesaplama sağlar.

MobileNet mimarisi, "Hesaplama kapasitesi ve model boyutu arasındaki dengeyi belirlemek için genişlik ve çözünürlük çoklayıcılarını kullanır." [56]

MobileNet, daha küçük ve daha hızlı modellerin gerektiği yerlerde kullanılacak bir çerçeve sağlar. Bu özellik, mobil cihazlar ve yerleşik sistemlerde, hesaplama ve depolama kaynaklarının sınırlı olduğu durumlarda özellikle kullanışlıdır. MobileNet mimarisi Şekil 4.8'de gösterilmektedir.



Şekil 4.8. MobileNet Mimarisi

Sonuç olarak, MobileNet, hafif ve hızlı, ancak yüksek performanslı bir model olması sebebiyle öne çıkar. Bu mimarinin esnekliği ve verimliliği, onu birçok uygulama için ideal bir seçim haline getirir, özellikle de yerleşik sistemler ve mobil cihazlar gibi kaynak sınırlı cihazlarda kullanılmak üzere tasarlanmıştır.

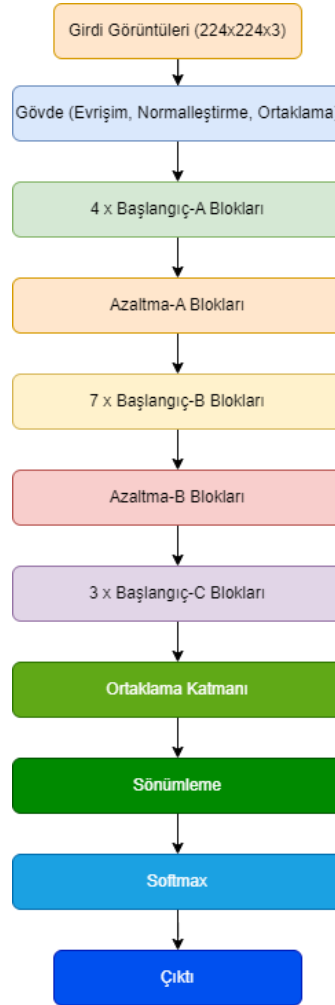
4.3.5. InceptionV4 Mimarisi

InceptionV4, Inception serisindeki bir başka ileri düzey mimari olarak öne çıkar. Bu model, hem Inception hem de ResNet mimarilerinin fikirlerini birleştiren ve bu iki mimarinin başarılı yönlerini birleştiren Inception-ResNet modelinin bir türevidir.

InceptionV4, önceki Inception modellerinde olduğu gibi, çeşitli ölçeklerde bilgi yakalama yeteneğini geliştirmek için farklı boyutlarda evrişimleri bir araya getiren başlangıç bloklarını kullanır. Bu, modelin daha karmaşık özellikler öğrenmesine ve daha doğru tahminler yapmasına olanak sağlar.

"InceptionV4, çeşitli boyuttaki evrişimleri bir arada kullanarak, çok ölçekli özellikler öğrenme yeteneğini artırır ve bu da sonuçta modelin daha yüksek performans elde etmesini sağlar." [57]

Inceptionv4 mimarisinin genel görseli şekilde, başlangıç blokları şekilde ve azaltma bloklar Şekil 4.9’da gösterilmiştir.



Şekil 4.9. Inceptionv4 Mimarisi

Sonuç olarak, InceptionV4, Inception serisinin önemli bir parçasıdır ve hem çeşitli ölçeklerde özellikler öğrenme yeteneği hem de daha derin ağlar oluşturma kapasitesi ile dikkat çeker. Bu özellikler, genellikle görüntü sınıflandırma ve nesne algılama gibi görsel tanıma görevlerinde kullanılan bu mimarinin gücünü oluşturur.

4.4. Model Eğitimi ve Test Süreçleri

Uygulamada Python programlama dilinde Pytorch kütüphanesinden yararlanılmıştır. Kullanılan bilgisayarın özellikleri; Intel(R) Core(TM) i7-10870H CPU @ 2.20GHz 2.21 GHz, 32.0 GB RAM, Nvidia GeForce RTX 3050 GPU 4GB şeklindedir. Ağ eğitimi için çeşitli faz denemeleri yapılmıştır.

Veri setleri eğitim öncesi birkaç düzenlemeye tabi tutulmuştur. Veri setindeki bir sınıftan diğerlerine göre daha az örnek varsa, bu durum modelin eğitimi üzerinde olumsuz bir etkiye sahip olabilir. Çünkü model, çoğunluk sınıfından daha fazla örnek gördüğü için, azınlık sınıfını öğrenmekte zorlanabilir. Bu nedenle, azınlık sınıfının ağırlığını artırarak, modelin bu sınıfı daha fazla dikkate almasını sağlarız. Bu amaçla her sınıfa ağırlığına göre bir çarpan atayarak öğrenimin tüm sınıflara yayılmasını sağlayabiliriz. Buradaki mantık kısaca çok etiketli sınıflandırma problemlerinde her sınıfın frekansını sayarak bu frekanslara göre ağırlıkların hesaplanmasıdır.

Eğitim sürecinde erken durdurma işlemi kullanılmıştır. Erken durma işlemi, modelin eğitimi sırasında belirli bir durumu kontrol etmeye ve eğer belirlenen şartlar sağlanırsa eğitimi durdurmaya dayanır. Bu özellikle, eğitim süresi boyunca modelin doğruluğunun arttığı ancak bir noktadan sonra doğruluğun düşmeye başladığı durumlarda yararlıdır. Bu durum genellikle aşırı uyumun bir belirtisidir. Erken durdurma işlemide aşırı uyumun engellenmesini sağlayan bir tekniktir.

Eğitim süresince kullanılan bütün mimarilerin son katmanlarına, bir ortaklama katmanı eklenmiştir. Ardından %50 olacak şekilde bir sönümlenme tanımlaması yapılmıştır yani her eğitim turunda rastgele seçilen yarı nöronlar devre dışı bırakılmıştır. Daha sonrasında yoğun katman eklenmiştir. Bu katman, her bir nöronun bir önceki katmandaki tüm nöronlara bağlı olduğu bir katmandır. Bu katman içerisinde Softmax aktivasyon fonksiyonu kullanılmıştır. Bu sayede her bir nöron çıkışı bir olasılığa dönüştürülmüştür ve toplamı 1 olacak şekilde normalize edilmiştir. Eklenen tüm katmanlar diğer mimarilere de aynı şekilde eklenmiş, eşit şartlar altında karşılaştırılma yapılmasına özen gösterilmiştir.

Yapılan testler sınıflandırma metrikleriyle değerlendirilmiş ve algoritmaların karşılaştırılmasıyla performans olarak en iyi sınıflandırıcı algoritmalar seçilmeye çalışılmıştır.

Aynı zamanda deneysel sonuçlar elde edilirken belirli hiper parametre uzayları oluşturulmuştur. Tüm algoritmalar için;

- Öğrenme Oranı: 0.01, 0.001, 0.0001
- Yığın Büyüklüğü: 32, 64, 128, 256
- Optimizasyon Algoritmaları: Stokastik Gradyan İnişi, Adam, RMSProp

DenseNet özelinde;

- Büyüme Oranı: 12, 24, 32, 40

MobileNet özelinde;

- Genişlik Çarpanı: 1, 0.75, 0.5, 0.25

Tüm algoritmalar eğitim stratejilerine göre en iyi hiper parametreler belirlenerek eğitilmiş ve en iyi sonuçlar elde edilmiştir.

4.5. Deneysel Sonular

4.5.1. 4 Sınıflı Veri Seti Deneysel Sonuları

4.5.1.1. ResNet Modelinin ImageNet Ağırlıklarıyla Eđitimi


ResNet modelinin eđitim sırasında elde ettiđi deđerler tabloda gsterilmektedir.

izelge 4.2. ResNet modeli eđitim sreci

ResNet50	Faz Sayısı	Eđitim Kaybı	Eđitim Bařarısı	Deđerleme Kaybı	Deđerleme Bařarısı
	1	0,5667	0,8188	1,7947	0,5689
	2	0,3184	0,8966	0,5193	0,854
	3	0,1914	0,9355	1,376	0,6951
	4	0,1921	0,939	1,9757	0,604
	5	0,1192	0,9625	0,333	0,8984
	6	0,0854	0,9722	0,1773	0,9334
	7	0,1097	0,964	1,2133	0,729
	8	0,0968	0,9695	0,4837	0,8668
	9	0,0757	0,9761	0,7642	0,8143
	10	0,0656	0,9763	0,2596	0,9703
	11	0,0525	0,9835	0,3707	0,889
	12	0,0485	0,9865	0,3587	0,9102
	13	0,0432	0,9899	0,5336	0,9199
	14	0,0389	0,9901	0,3569	0,9089
	15	0,0332	0,9908	0,3074	0,8966

ResNet mimarisi, eđitim srecinde faz sayısı arttıka eđitim kaybını azaltıp, eđitim bařarısını arttırmaktadır. 1. fazda eđitim kaybı 0.5667 iken, 15. fazda 0.0332'ye dşmektedir ve eđitim bařarısı aynı srete %81.88'den %99.08'e ıkmaktadır. Ancak, deđerleme kaybı ve bařarısı dalgalanmalar gsterir. Deđerleme bařarısı, 6. fazda %93.34 ve 10. fazda %97.03 ile iki zirve yapar.

ResNet modeli iin modelin hi grmediđi test verisindeki sınıflandırma sonuları Őekilde gsterilmiřtir.



Şekil 4.10. ResNet Modeli Sınıflandırma Matrisi

- Model, Glioma sınıfına ait 290 örnek doğru bir şekilde Glioma olarak sınıflandırılmış, ancak 8 tanesi yanlışlıkla Meningioma olarak ve 2 tanesi Pituitary olarak sınıflandırılmıştır.
- Meningioma sınıfında, 283 örnek doğru bir şekilde Meningioma olarak sınıflandırılırken, 6'sı Glioma, 6'sı NoTumor ve 11'i Pituitary olarak yanlış sınıflandırılmıştır.
- NoTumor sınıfı, model tarafından oldukça başarılı bir şekilde tahmin edilmiştir. 402 örnek doğru bir şekilde sınıflandırılırken, sadece 3 tanesi yanlışlıkla Meningioma olarak sınıflandırılmıştır.
- Son olarak, Pituitary sınıfında, 297 örnek doğru bir şekilde sınıflandırılırken, sadece 3 tanesi Meningioma olarak yanlış sınıflandırılmıştır.
- Bu sonuçlar, modelin özellikle NoTumor ve Pituitary sınıflarında yüksek doğrulukla sınıflandırma yaptığını, ancak Glioma ve Meningioma sınıfları arasında hafif bir karışıklık yaşandığını göstermektedir. Modelin performansını artırmak için, özellikle Glioma ve Meningioma sınıfları arasındaki karışıklığı azaltmaya yönelik ek optimizasyonlar ve ayarlamalar yapılabilir.

ResNet modeli için test veri seti üzerinde yapılan sınıflandırma sonuçlarının tablosu verilmiştir.

Çizelge 4.3. ResNet Modeli Sınıflandırma Raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Glioma	0.98	0.97	0.97	300
Meningioma	0.95	0.92	0.94	306
Notumor	0.99	0.99	0.99	405
Pituitary	0.96	0.99	0.97	300
Doğruluk			0.97	1311
Makro Ort.	0.97	0.97	0.97	1311
Ağırlıklı Ort.	0.97	0.97	0.97	1311

Glioma sınıfı için, modelin Hassasiyeti %98, Duyarlılığı %97 ve F1-Skoru %97'dir. Bu, modelin Glioma sınıfını tespit etmede yüksek doğruluk ve güvenilirlik sergilediğini göstermektedir.

Meningioma sınıfında, Hassasiyet %95, Duyarlılık %92 ve F1-Skoru %94'tür. Bu, modelin Meningioma sınıfını tespit etmede oldukça iyi performans gösterdiğini, ancak biraz daha düşük duyarlılıkla Glioma'ya kıyasla, göstermektedir.

NoTumor sınıfı, en yüksek performansı sergilemektedir. Hassasiyet ve Duyarlılık değerleri %99 ve F1-Skoru da %99'dur. Bu, modelin NoTumor sınıfını tespit etmede olağanüstü bir başarı gösterdiğini belirtir.

Pituitary sınıfı için, modelin Hassasiyeti %96, Duyarlılığı %99 ve F1-Skoru %97'dir. Yine yüksek bir performans gözlemlenmektedir.

Modelin genel doğruluğu %97 olarak bulunmuş olup, bu da modelin tüm sınıflarda oldukça yüksek bir doğrulukla tahminler yaptığını göstermektedir.

4.5.1.2. ResNet Modelinin ImageNet Ağırlıkları Olmadan Eğitimi

ResNet modelinin ImageNet ağırlıkları olmadan eğitimi sırasında elde ettiği başarı değerleri tabloda gösterilmektedir.

Çizelge 4.4. ResNet modeli eğitim süreci

ResNet50	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	1.056	0.6425	1.9163	0.4521
	2	0.7111	0.7453	0.8918	0.6554
	3	0.5467	0.7959	0.7093	0.7535
	4	0.4613	0.8383	0.5451	0.7804
	5	0.4166	0.8523	0.6531	0.7325
	6	0.3615	0.8769	3.112	0.5023
	7	0.3099	0.8944	0.6615	0.7839
	8	0.2736	0.9042	3.6368	0.6565
	9	0.2635	0.9073	0.3901	0.8633
	10	0.2109	0.9287	1.1636	0.7348
	11	0.2078	0.9351	0.4263	0.861
	12	0.1692	0.9413	0.3624	0.8995
	13	0.155	0.9477	1.424	0.7477
	14	0.1796	0.9413	1.1334	0.7886
	15	0.1335	0.9568	1.249	0.7862
	16	0.1293	0.9568	0.3568	0.9077
	17	0.1178	0.9615	0.593	0.8481
	18	0.0931	0.9712	0.5587	0.882
	19	0.1019	0.9695	0.5745	0.9077
	20	0.078	0.9753	0.2387	0.9439
	21	0.0628	0.9804	0.4508	0.8902
	22	0.0935	0.9675	1.2772	0.8668
	23	0.0887	0.9751	0.6438	0.8586
	24	0.0884	0.9722	0.3882	0.8925
	25	0.0921	0.973	0.195	0.9416
	26	0.0809	0.9734	1.3239	0.8294
	27	0.0914	0.9736	0.3099	0.9346
	28	0.0408	0.9885	0.299	0.9346
	29	0.0267	0.9926	0.3682	0.9159
	30	0.0626	0.979	0.3456	0.9241


Modelin 1. faz ile 5. faz arasında hem eğitim hem de değerlendirme setinde yüksek bir kayıp yaşadığı görülmektedir, ancak eğitim kaybı sürekli azalırken, değerlendirme kaybı dalgalanmaktadır. Bu, modelin eğitim verilerini öğrenmeye başladığını, ama bu fazlar arasında henüz genelleme yapma yeteneğini tam olarak geliştirmediğini gösterir.

6. faz ve 10. fazlar arasında, modelin eğitim kaybı ve değerlendirme kaybı arasındaki uçurum artmaktadır. Bu, modelin eğitim verilerini fazlasıyla öğrenmeye, yani aşırı uyuma başladığını göstermektedir.

11. ve 15. fazlar arasında, modelin eğitim başarısı yükselirken, değerlendirme başarısında belirgin bir iyileşme görüyoruz. Bu, modelin eğitim verilerinden öğrenmeye ve bu bilgileri değerlendirme verilerine genelleme kabiliyetini bu fazlar arasında geliştirdiğini gösterir.

25. faz değerlendirme başarısı ve eğitim başarısı açısından en iyi faz olarak belirlenmiştir.

ResNet modeli için modelin hiç görmediği test verisindeki sınıflandırma sonuçları şekilde verilmiştir.



Şekil 4.11. ResNet modeli için sınıflandırma matrisi

- Model, 269 Glioma, 259 Meningioma, 405 Notumor ve 289 Pituitary'yi doğru bir şekilde sınıflandırmıştır.

- Model, 24 Meningioma ve 7 Pituitary sınıflarını yanlışlıkla Glioma olarak sınıflandırmıştır.
- Model, 15 Glioma, 27 Notumor ve 5 Pituitary sınıfını yanlışlıkla Meningioma olarak sınıflandırmıştır.
- Model, Notumor sınıfını mükemmel bir şekilde belirlemiştir; hiçbir yanlış sınıflandırma yapmamıştır.
- Model, 9 Meningioma ve 2 Notumor'u yanlışlıkla Pituitary olarak sınıflandırmıştır.
- Modelin genel performansı iyi görünmekte ve özellikle Notumor sınıfını sınıflandırmada mükemmel sonuçlar elde etmiştir.
- Ancak, model Glioma ve Pituitary sınıflarını belirlerken bazen Meningioma sınıfını karıştırıyor; Meningioma sınıfını belirlerken de Glioma ve Notumor sınıflarını karıştırıyor.

ResNet modeli için sınıflandırma sonuçları tabloda verilmiştir.

Çizelge 4.5. ResNet modeli sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Glioma	0.95	0.9	0.92	300
Meningioma	0.89	0.85	0.87	306
Notumor	0.93	1	0.97	405
Pituitary	0.96	0.96	0.96	300
Doğruluk			0.93	1311
Makro Ort.	0.93	0.93	0.93	1311
Ağırlıklı Ort.	0.93	0.93	0.93	1311

"Glioma" tümör türü için, model %95 hassasiyet ve %90 duyarlılık oranlarına sahiptir. Bu, modelin "glioma" türündeki tümörleri doğru bir şekilde tanıma yeteneğini gösterir. F1 skoru, hassasiyet ve duyarlılık arasında dengeyi gösteren bir metrik olduğu için, "glioma" için %92'lik F1 skoru, modelin bu türdeki tümörlerin sınıflandırılmasında dengeli bir performans sergilediğini gösterir.

"Meningioma" tümör türünde ise, model %89 hassasiyet ve %85 duyarlılık oranlarına sahiptir. F1 skoru %87 olarak hesaplanmıştır, bu da modelin "meningioma" türündeki tümörlerin sınıflandırılmasında iyi bir denge sağladığını gösterir.

"Notumor" sınıfında, model %93 hassasiyet ve %100 duyarlılık oranlarına ulaşmıştır. Bu, modelin tümör içermeyen durumları mükemmel bir şekilde tahmin ettiğini gösterir. Bu sınıf için hesaplanan F1 skoru %97'dir.

"Pituitary" tümör türünde, model %96 hassasiyet ve %96 duyarlılık oranlarına sahiptir. F1 skoru da %96'dır, bu da modelin "pituitary" tümör türünde dengeli ve yüksek bir performans sergilediğini gösterir.

Modelin genel doğruluk oranı %93'tür. Bu, modelin tüm tümör tiplerini genel olarak doğru bir şekilde tahmin ettiğini gösterir. Ayrıca, hassasiyet, duyarlılık ve F1 skoru için makro ve ağırlıklı ortalama değerlerin her ikisi de %93 olarak hesaplanmıştır.

Bu sonuçlar, modelin genel olarak yüksek bir performans sergilediğini, tüm tümör türlerini etkili bir şekilde sınıflandırabildiğini göstermektedir.

4.5.1.3. EfficientNetB1 Modelinin ImageNet Ağırlıklarıyla Eğitimi

EfficientNetB1 modelinin ImageNet ağırlıkları olmadan eğitimi sırasında elde ettiği başarı değerleri tabloda gösterilmektedir.


Çizelge 4.6. EfficientNet için eğitim süreci

EfficientNetB1	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	0.3217	0.8882	0.4079	0.8867
	2	0.1793	0.9407	0.1202	0.9696
	3	0.1054	0.9656	0.2688	0.9147
	4	0.0772	0.9741	0.0642	0.9766
	5	0.0488	0.9843	0.1208	0.9696
	6	0.1063	0.9681	0.4812	0.9206
	7	0.0526	0.9829	0.1511	0.9556
	8	0.0429	0.9876	0.0549	0.979
	9	0.0468	0.9831	0.2196	0.9428
	10	0.0275	0.9914	0.2387	0.9556
	11	0.0357	0.9895	0.0713	0.9755
	12	0.0452	0.9864	0.0695	0.979
	13	0.0285	0.9922	0.112	0.9603

Eğitim verilerine dayanarak, modelin eğitim süresi boyunca eğitim hatasının genellikle azaldığı ve eğitim doğruluğunun arttığı görülüyor. Bu, modelin eğitim verilerini giderek daha iyi bir şekilde öğrendiğini ve modelin karmaşıklığını ve kapasitesini artırdığını göstermektedir.

Eğitim ve değerlendirme başarısını dikkate alarak, genel olarak 14. fazın en iyi performansı gösterdiği söylenebilir. Bu fazda, eğitim kaybı en düşük seviyede (0.0730) ve eğitim başarısı en yüksek seviyede (0.9763) iken aynı zamanda, değerlendirme kaybı (0.1598) nispeten düşük ve değerlendirme başarısı da (0.9544) oldukça yüksek gözlemlenmektedir.

EfficientNet modeli için modelin hiç görmediği test verisindeki sınıflandırma sonuçları şekilde verilmiştir.



Şekil 4.12. EfficientNet için sınıflandırma matrisi

- Model, 284 Glioma, 304 Meningioma, 401 Notumor ve 299 Pituitary'yi doğru bir şekilde sınıflandırmıştır.
- Model, Glioma sınıfını belirlemede genellikle başarılıdır, ancak 16 Meningioma sınıfını yanlışlıkla Glioma olarak sınıflandırmıştır.
- Model, Meningioma sınıfını belirlemede çok başarılıdır, yanlışlıkla sadece 2 Pituitary sınıfını Meningioma olarak sınıflandırmıştır.
- Model, Notumor sınıfını mükemmel bir şekilde belirlemiştir, sadece 4 Pituitary sınıfını yanlışlıkla Notumor olarak sınıflandırmıştır.
- Model, Pituitary sınıfını belirlemede çok başarılıdır, sadece 1 Meningioma'yı yanlışlıkla Pituitary olarak sınıflandırmıştır.
- Genel olarak, modelin tüm sınıfları doğru bir şekilde belirleme kabiliyeti oldukça yüksektir.

EfficientNet modeli için test veri seti üzerinde yapılan sınıflandırma sonuçlarının tablosu verilmiştir.

Çizelge 4.7. EfficientNet için sınıflandırma matrisi

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Glioma	1	0.95	0.97	300
Meningioma	0.95	0.99	0.97	306
Notumor	1	0.99	1	405
Pituitary	0.98	1	0.99	300
Doğruluk			0.98	1311
Makro Ort.	0.98	0.98	0.98	1311
Ağırlıklı Ort.	0.98	0.98	0.98	1311

Sonuçlar çeşitli beyin tümörü tiplerini sınıflandırmada kullanılan modelin performansının önemli ölçüde geliştiğini göstermektedir. Modelin genel doğruluk oranı artarak %98'e çıkmıştır, bu da veri setindeki örneklerin büyük bir kısmını doğru bir şekilde sınıflandırdığını gösterir.

Modelin, glioma ve notumor sınıflarını belirlemede hassasiyet oranları %100'e çıkmıştır. Bu, modelin artık bu sınıfların çoğunu hemen hemen mükemmel bir şekilde tahmin ettiği anlamına gelir. Özellikle glioma sınıfında duyarlılık oranı %95'e yükselmiştir, bu da modelin bu sınıftaki örnekleri kaçırma oranının düştüğünü gösterir.

Meningioma sınıfında, modelin hassasiyeti %95'e çıkmış ve duyarlılık oranı %99'a yükselmiştir. Bu, modelin bu sınıfı tahmin etme konusunda daha başarılı hale geldiğini ve gerçek meningioma örneklerinin neredeyse tümünü doğru bir şekilde sınıflandırdığını gösterir.

Notumor ve pituitary sınıflarında, modelin hassasiyet ve duyarlılık oranları oldukça yüksektir. Bu sonuçlar, modelin bu sınıfları belirlemede mükemmel bir iş çıkardığını göstermektedir.

Ağırlıklı ortalama değerleri, her sınıfın destek oranlarına göre ağırlıklandırıldığı için, modelin tüm sınıfların sınıflandırılmasındaki genel başarısını gösterir. Bu durumda,

ağırlıklı ortalama değerlerin de oldukça yüksek olduğunu (%98 hassasiyet, %98 duyarlılık ve %98 F1-Skoru) görüyoruz. Bu, modelin tüm sınıflar arasında genel olarak yüksek bir performans sergilediğini gösterir.

Sonuç olarak model, beyin tümörü tiplerini sınıflandırmada yüksek doğruluk, hassasiyet ve duyarlılık oranlarını sağlamıştır. Özellikle, belirli sınıflarda (örneğin glioma ve meningioma) daha önce belirlenen zorlukların üstesinden gelinmiş ve bu sınıfların doğruluk oranları önemli ölçüde artmıştır.

4.5.1.4. EfficientNetB1 Modelinin ImageNet Ağırlıkları Olmadan Eğitimi

EfficientNet modelinin eğitim sırasında elde ettiği değerler tabloda gösterilmektedir.

Çizelge 4.8. EfficientNet modeli eğitim süreci

EfficientNetB1	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	1,0355	0,5647	2,3303	0,3400
	2	0,6660	0,7624	1,1379	0,6110
	3	0,5103	0,8204	0,5849	0,7593
	4	0,3851	0,8639	0,3020	0,8960
	5	0,3035	0,8956	0,6601	0,8084
	6	0,2272	0,9261	0,2991	0,9077
	7	0,1943	0,9372	0,2226	0,9287
	8	0,1592	0,9473	0,3897	0,8820
	9	0,1272	0,9561	0,1539	0,9591
	10	0,1061	0,9662	0,2717	0,9124
	11	0,0979	0,9681	0,5204	0,8855
	12	0,1309	0,9586	0,3168	0,9112
	13	0,0947	0,9693	0,2517	0,9299
	14	0,0730	0,9763	0,1598	0,9544

1. fazda, eğitim kaybı oldukça yüksek ve eğitim doğruluk oranı da düşük gözlemlenmiştir. Bu durum, modelin başlangıç ağırlıklarının rastgele seçildiği ve henüz öğrenme sürecinin başında olduğu için beklenebilmektedir. Değerleme kaybı ve değerlendirme başarısı da sırasıyla eğitim kaybı ve eğitim başarısından düşük gözlemlenmiştir.


2. fazda, eğitim kaybı önemli ölçüde düşüş göstermiştir ve eğitim başarısı artmıştır. Bu, modelin öğrenme sürecinde ilerleme kaydettiğini gösterir. Değerleme metrikleri de aynı ölçüde gelişim göstermektedir. Bu trend, 7. faza kadar devam etmiştir.

Ancak, 8. ve 11. fazlar arasında, modelin performansı bir miktar dalgalanma göstermektedir. Eğitim kaybı, değerlendirme kaybı ve doğruluk değerlerinde küçük bir yükselme ve düşüş gözlemlenmiştir.

12. fazdan itibaren, model tekrar düzenli bir ilerleme göstermeye başlamıştır. 14. Fazda, eğitim kaybı 0,0730 ve eğitim doğruluk oranı 0,9763'e ulaşmıştır. Değerleme kaybı ve değerlendirme başarısı sırasıyla 0,1598 ve 0,9544 oldu.

Modelin çıktılarına göre, 9. faz modelin en iyi performansını göstermektedir. Bu fazda, eğitim kaybı düşük (0,1272), eğitim doğruluk oranı yüksek (0,9561), değerlendirme kaybı en düşük (0,1539) ve değerlendirme doğruluk oranı en yüksek (0,9591) olarak izlenmektedir. Bu, modelin bu aşamada genellemeyi en iyi şekilde gerçekleştirdiğini gösterir. Ancak, 14. fazda eğitim metrikleri daha iyi görünüyorsa da, değerlendirme metriklerinin biraz düştüğünü not etmek önemlidir, bu da belirli bir aşamadan sonra modelin biraz aşırı uyum sergilemeye başladığını gösterebilir.

EfficientNet modeli için modelin hiç görmediği test verisindeki sınıflandırma sonuçları şekilde verilmiştir.



Şekil 4.13. EfficientNet modeli sınıflandırma matrisi

- Model, Glioma sınıfında 271 doğru sınıflandırma yapmış, ancak 28 Meningioma ve 1 Notumor'u yanlışlıkla Glioma olarak sınıflandırmış.
- Meningioma sınıfında model 289 doğru sınıflandırma yapmış. Ancak, 4 Glioma, 8 Notumor ve 5 Pituitary'yi yanlışlıkla Meningioma olarak sınıflandırmış.
- Notumor sınıfında model 398 doğru sınıflandırma yapmış. Ancak, 1 Glioma, 5 Meningioma ve 1 Pituitary'yi yanlışlıkla Notumor olarak sınıflandırmış.
- Pituitary sınıfında model 294 doğru sınıflandırma yapmış. Ancak, 1 Glioma ve 5 Meningioma'yı yanlışlıkla Pituitary olarak sınıflandırmış.
- Model, özellikle Notumor ve Pituitary sınıflarını doğru bir şekilde sınıflandırmada yüksek performans gösteriyor.
- Model, Glioma ve Meningioma sınıflarını birbirinden ayırt etmede zorluk çekiyor.

EfficientNet modeli için test veri seti üzerinde yapılan sınıflandırma sonuçlarının tablosu verilmiştir.

Çizelge 4.9. EfficientNet modeli sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Glioma	0.98	0.9	0.94	300
Meningioma	0.88	0.94	0.91	306
Notumor	0.98	0.98	0.98	405
Pituitary	0.98	0.98	0.98	300
Doğruluk			0.95	1311
Makro Ort.	0.96	0.95	0.95	1311
Ağırlıklı Ort.	0.96	0.95	0.96	1311

Sonuçlar, çeşitli beyin tümörü tiplerini sınıflandırmada kullanılan modelin genel olarak yüksek bir performansa sahip olduğunu göstermektedir. Modelin genel doğruluk oranı %95'tir, bu da veri setindeki örneklerin büyük bir kısmını doğru bir şekilde sınıflandırdığını göstermektedir.

Model, glioma ve notumor sınıflarını belirlemede %98'lik bir hassasiyet ile oldukça başarılıdır, bu da modelin bu sınıfların çoğunu doğru bir şekilde tahmin ettiği anlamına

gelmektedir. Ancak, glioma sınıfında %90'lık bir duyarlılık oranı vardır, bu da modelin bu sınıftaki bazı örnekleri kaçırdığı anlamına gelmektedir.

Meningioma sınıfında ise modelin hassasiyeti %88 ve duyarlılık oranı %94'tür. Bu, modelin bu sınıfı tahmin etmede bir miktar zorluk çektiğini, ancak gerçek meningioma örneklerinin büyük bir kısmını doğru bir şekilde sınıflandırdığını gösterir.

Notumor ve pituitary sınıfları için hem hassasiyet hem de duyarlılık oranları %98'dir. Bu sonuçlar, modelin bu sınıfları belirlemede mükemmel bir iş çıkardığını göstermektedir.

Ağırlıklı ortalama değerlerinin de yüksek olduğunu (%96 hassasiyet, %95 duyarlılık ve %96 F1-Skoru) görüyoruz. Bu, modelin tüm sınıflar arasında genel olarak yüksek bir performans sergilediğini gösterir.

Sonuç olarak model, beyin tümörü tiplerini sınıflandırmada yüksek doğruluk, hassasiyet ve duyarlılık oranları sağlamıştır. Ancak, belirli sınıflarda (örneğin glioma ve meningioma) daha düşük performans gösterme eğilimindedir.

4.5.1.5. MobileNet Modelinin ImageNet Ağırlıklarıyla Eğitimi

MobileNet modelinin eğitim sırasında elde ettiği değerler tabloda gösterilmektedir.

Çizelge 4.10. MobileNet modeli eğitim süreci

MobileNet	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	0.4015	0.8818	0.3674	0.8949
	2	0.1906	0.9382	0.1658	0.9451
	3	0.1455	0.9539	0.2342	0.9299
	4	0.0865	0.9738	0.1709	0.9474
	5	0.0637	0.979	0.2037	0.9439
	6	0.0745	0.9788	0.1478	0.9521
	7	0.0945	0.9716	0.2661	0.9217
	8	0.0654	0.9767	0.1139	0.9638
	9	0.0519	0.9846	0.0992	0.9673
	10	0.0544	0.9823	0.1942	0.9451
	11	0.0372	0.9885	0.1714	0.9533
	12	0.0505	0.9866	0.0728	0.9825
	13	0.0628	0.9823	1.3205	0.7593
	14	0.0451	0.985	0.0766	0.972
	15	0.0479	0.9843	0.2072	0.9474
	16	0.0613	0.9837	0.3249	0.9264
	17	0.0539	0.9827	0.1723	0.9533

İlk fazda, modelin eğitim kaybı 0.4015, eğitim başarısı ise %88.18'dir. Bu, modelin başlangıçta belirlenen ağırlıklarla birlikte başarılı bir şekilde öğrenmeye başladığını göstermektedir. Değerleme kaybı ve başarısı ise sırasıyla 0.3674 ve %89.49'dur. Bu, modelin görmediği veriler üzerinde iyi bir genelleme yapmaya başladığını göstermektedir.

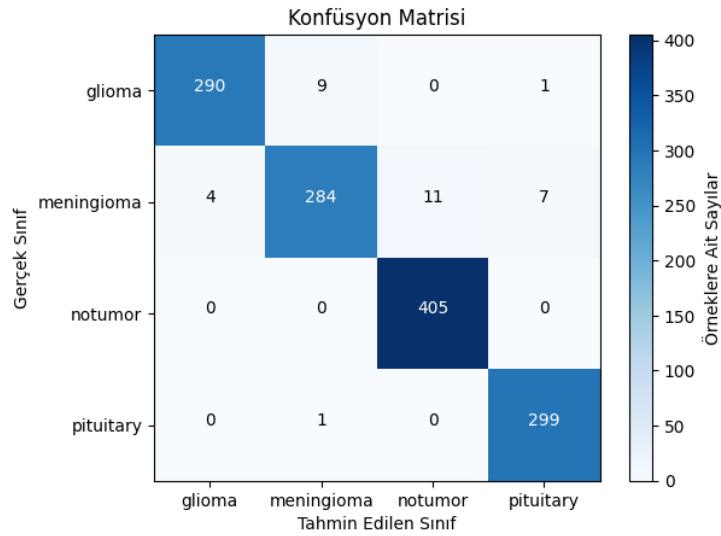
2. fazda, hem eğitim hem de değerlendirme kaybı düşmeye devam ederken, başarı oranları artmıştır. Modelin öğrenmeye devam ettiğini ve genelleme yeteneğini geliştirdiğini göstermektedir. 3. fazda ise, değerlendirme kaybında bir artış (0.2342) ve değerlendirme

başarısında bir azalma (%92.99) görülür. Bu durum, modelin belirli bir miktarda aşırı uyum yapmaya başladığını gösterebilir.

Bu trend, modelin eğitim süresince birkaç kez daha tekrarlanmaktadır. Özellikle 5., 7., 10., 13., 15. ve 16. fazlar belirgin bir şekilde yüksek değerlendirme kaybına sahiptir.

12. fazda, model değerlendirme başarısı en yüksek değerine (%98.25) ulaşırken, değerlendirme kaybı da en düşük seviyesine (0.0728) inmiştir. Modelin en iyi genelleme yeteneğini bu dönemde gösterdiğini belirtir. Aynı zamanda 12. faz, hem eğitim başarısının yüksek (%98.66), hem de eğitim kaybının düşük (0.0505) olduğu bir dönem olduğu için iyi bir seçenek gibi görünmektedir.

MobileNet modeli için modelin hiç görmediği test verisindeki sınıflandırma sonuçları şekilde verilmiştir.



Şekil 4.14. MobileNet modeli sınıflandırma matrisi

- Model, Glioma sınıfında 290 doğru sınıflandırma yapmış, ancak 9 Meningioma ve 1 Pituitary'yi yanlışlıkla Glioma olarak sınıflandırmış.
- Meningioma sınıfında model 284 doğru sınıflandırma yapmış. Ancak, 4 Glioma, 11 Notumor ve 7 Pituitary'yi yanlışlıkla Meningioma olarak sınıflandırmış.
- Notumor sınıfında model, tüm 405 sınıflandırmayı doğru bir şekilde yapmış ve hiçbir yanlış sınıflandırma yapmamış.

- Pituitary sınıfında model 299 doğru sınıflandırma yapmış ve sadece 1 Meningioma'yı yanlışlıkla Pituitary olarak sınıflandırmış.
- Modelin performansı özellikle Notumor ve Pituitary sınıflarında son derece yüksektir.
- Model, Glioma ve Meningioma sınıflarını birbirinden ayırt etmek konusunda ve Meningioma sınıfını Notumor ve Pituitary sınıflarından ayırt etme konusunda bir miktar zorluk çekmektedir.

MobileNet modeli için test veri seti üzerinde yapılan sınıflandırma sonuçlarının tablosu verilmiştir.

Çizelge 4.11. MobileNet modeli sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Glioma	0.99	0.97	0.98	300
Meningioma	0.97	0.93	0.95	306
Notumor	0.97	1	0.99	405
Pituitary	0.97	1	0.99	300
Doğruluk			0.97	1311
Makro Ort.	0.97	0.97	0.97	1311
Ağırlıklı Ort.	0.97	0.97	0.97	1311

Sonuçlar, çeşitli beyin tümörü tiplerini sınıflandırmada kullanılan modelin genel olarak yüksek bir performans sergilediğini göstermektedir. Modelin görmediği test verisinde gösterdiği genel doğruluk oranı %97'dir, bu da veri setindeki örneklerin büyük bir kısmını doğru bir şekilde sınıflandırdığını göstermektedir.

Model, glioma sınıfını belirlemede %99 hassasiyet oranıyla yüksek bir başarı göstermiştir. Modelin bu sınıfın çoğunu doğru bir şekilde tahmin ettiği anlamına gelmektedir. Ayrıca, glioma sınıfında %97 duyarlılık oranı vardır, bu da modelin bu sınıftaki bazı örnekleri kaçırmadığı anlamına gelmektedir.

Meningioma sınıfında, modelin hassasiyeti %97 iken, duyarlılık oranı %93'tür. Bu, modelin bu sınıfı tahmin etme konusunda başarılı olduğunu, ancak gerçek meningioma örneklerinin küçük bir kısmını kaçırdığını göstermektedir.

Notumor ve pituitary sınıflarında, modelin hassasiyet ve duyarlılık oranları oldukça yüksektir (%97 ve %100, %97 ve %100 sırasıyla). Bu sonuçlar, modelin bu sınıfları belirlemede mükemmel bir iş çıkardığını göstermektedir.

Ağırlıklı ortalama değerlerinin de oldukça yüksek olduğu (%97 hassasiyet, %97 duyarlılık ve %97 F1-Skoru) görülmektedir. Modelin tüm sınıflar arasında genel olarak yüksek bir performans sergilediğini göstermektedir.

4.5.1.6. MobileNet Modelinin ImageNet Ağırlıkları Olmadan Eğitimi

MobileNet modelinin eğitim sırasında elde ettiği değerler tabloda gösterilmektedir.

Çizelge 4.12. ImageNet ağırlıkları kullanılmayan MobileNet modeli için eğitim süreci

	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
MobileNet	1	0.8065	0.6907	2.1014	0.257
	2	0.5153	0.8151	2.098	0.2897
	3	0.4082	0.8575	0.4333	0.8481
	4	0.373	0.8705	1.4538	0.5724
	5	0.3401	0.8816	1.1149	0.6343
	6	0.2992	0.8929	1.2026	0.6682
	7	0.2693	0.9077	0.9959	0.7079
	8	0.246	0.9147	1.4013	0.6659


Başlangıçta, modelin eğitim setindeki doğruluk oranı %69 olarak belirlenmiş ve ilk faz sonunda değerlendirme setindeki doğruluk oranı %25.7 olmuştur. Ancak, ilerleyen fazlarla birlikte, modelin eğitim doğruluğu sürekli olarak artmış ve 8. faz sonunda %91.47'ye ulaşmıştır.

Benzer şekilde, modelin değerlendirme doğruluğu da sürekli olarak artmıştır, ancak daha fazla dalgalanma göstermiştir. 3. fazda, değerlendirme doğruluğu %84.81'e yükselmiş, ancak sonraki fazlarda bir miktar düşüş göstermiştir. 8. faz sonunda, değerlendirme doğruluğu %66.59'a düşmüştür.

Eđitim kaybı deęerleri de eđitim s¼reci boyunca d¼ř¼ř g¼stermiřtir, bu da modelin eđitim s¼recinde daha az hata yaptığını g¼stermektedir. Modelin eđitim setindeki ilk kayıp deęeri 0.8065 iken, 8. faz sonunda bu deęer 0.246'ya d¼řm¼řt¼r. Deęerleme kaybı, eđitim s¼resince bir miktar dalgalanma g¼stermiřtir, ancak genel eđilim d¼ř¼ř y¼n¼ndedir.

Bu sonular, modelin genel olarak ¼đrenme yeteneđini geliřtirdiđini, ancak deęerleme setindeki performansının daha fazla iyileřtirilmesi gerektiđini g¼stermektedir. Bu řartlar, modelin genelleřtirme yeteneđini olumsuz etkileyebilir ve bilinmeyen verilere karřı performansını d¼ř¼rebilir.

MobileNet modeli iin modelin hi g¼rmediđi test verisindeki sınıflandırma sonuları řekilde verilmiřtir.



řekil 4.15. MobileNet sınıflandırma matrisi

- Glioma sınıfında, modelin 185 dođru sınıflandırma yapmasına karřın, 3 Meningioma, 32 Notumor ve 80 Pituitary'yi yanlıřlıkla Glioma olarak sınıflandırdığı g¼r¼lm¼řt¼r.
- Meningioma sınıfında, modelin sadece 46 dođru sınıflandırma yapabilmiř ve 88 Glioma, 34 Notumor ve 138 Pituitary'yi yanlıřlıkla Meningioma olarak sınıflandırdığı g¼r¼lm¼řt¼r.

- Notumor sınıfında, modelin 336 doğru sınıflandırma yapmış, ancak 4 Glioma, 9 Meningioma ve 56 Pituitary'yi yanlışlıkla Notumor olarak sınıflandırdığı görülmüştür.
- Pituitary sınıfında, modelin 299 doğru sınıflandırma yapmış ve sadece 1 Notumor'u yanlışlıkla Pituitary olarak sınıflandırdığı görülmüştür.
- Model, özellikle Glioma ve Meningioma sınıflarını doğru bir şekilde sınıflandırmakta zorlanmaktadır. Bu sınıfları, özellikle Pituitary ile karıştırma eğilimindedir.
- Modelin Notumor ve Pituitary sınıflarını sınıflandırmada diğer sınıflara göre yüksek performans gösterdiği görülmektedir.

MobileNet modeli için test veri seti üzerinde yapılan sınıflandırma sonuçlarının tablosu verilmiştir.

Çizelge 4.13. MobileNet sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Glioma	0.67	0.62	0.64	300
Meningioma	0.79	0.15	0.25	306
Notumor	0.83	0.83	0.83	405
Pituitary	0.52	1	0.68	300
Doğruluk			0.66	1311
Makro Ort.	0.7	0.65	0.6	1311
Ağırlıklı Ort.	0.71	0.66	0.62	1311

"Glioma" tümör türünü belirlemede, model %67'lik bir hassasiyet ve %62'lik bir duyarlılık sergilemiştir. F1 skoru ise %64 olarak hesaplanmıştır. Bu, modelin "glioma" türündeki tümörleri nispeten iyi bir doğrulukla tanımladığını göstermektedir.

"Meningioma" tümör türünde ise, model hassasiyeti %79 iken, duyarlılığı düşük kalmış ve %15 olarak belirlenmiştir. Bu durum, modelin "meningioma" türünde birçok yanlış pozitif belirlediğini ve gerçekte "meningioma" olan birçok durumu kaçırdığını gösterir. Bu nedenle, F1 skoru da bu tür için düşük çıkmış ve %25 olarak hesaplanmıştır.

"Notumor" sınıfında, model %83'lük hem hassasiyet hem de duyarlılık göstermiştir. Bu, modelin tümör içermeyen durumları nispeten yüksek bir doğrulukla tahmin ettiğini gösterir. F1 skoru da bu sınıf için %83 olarak hesaplanmıştır.

"Pituitary" tümör türünde, model %52'lik bir hassasiyet sergilemiştir ancak duyarlılık %100 olarak belirlenmiştir. Bu, modelin "pituitary" tümörlerini her zaman doğru bir şekilde belirlediğini, ancak aynı zamanda birçok yanlış pozitif tahminde bulunduğunu gösterir. F1 skoru, hassasiyet ve duyarlılık arasındaki dengeyi gösterir ve bu tür için %68 olarak hesaplanmıştır.

Modelin genel doğruluğu %66 olarak belirlenmiştir. Ayrıca, makro ortalama değerlerine bakıldığında, hassasiyetin %70, duyarlılığın %65 ve F1 skorunun %60 olduğu görülmüştür. Ağırlıklı ortalama değerlerine bakıldığında ise, hassasiyetin %71, duyarlılığın %66 ve F1 skorunun %62 olduğu belirlenmiştir.

Bu sonuçlar, modelin belirli tümör türlerini diğerlerinden daha iyi tahmin ettiğini göstermekle birlikte genel başarının düşük kaldığı da söylenebilir. Özellikle "meningioma" tümör türünün belirlenmesinde modelin performansı önemli ölçüde düşmektedir.

4.5.1.7. InceptionV4 Modelinin ImageNet Ağırlıklarıyla Eğitimi

InceptionV4 modelinin eğitim sırasında elde ettiği değerler tabloda gösterilmektedir.

Çizelge 4.14. InceptionV4 modeli için eğitim süreci

InceptionV4	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	0.3472	0.8847	0.3915	0.847
	2	0.1864	0.9372	0.7809	0.75
	3	0.1219	0.9572	0.2435	0.9369
	4	0.1133	0.9636	0.3482	0.9136
	5	0.0866	0.9718	0.2514	0.9194
	6	0.0913	0.9703	0.0908	0.9766
	7	0.0414	0.9864	0.3043	0.9077
	8	0.0411	0.9858	0.1682	0.9428
	9	0.0593	0.9829	0.0669	0.9766
	10	0.0407	0.9866	0.8292	0.8213
	11	0.0545	0.9813	0.1591	0.9544
	12	0.0436	0.9866	0.1548	0.9556
	13	0.0174	0.993	1.7221	0.7091
	14	0.0355	0.9911	0.0847	0.9755

Modelin eğitim kaybı ilk fazdan başlayarak genel olarak azalmaktadır. Bu, modelin eğitim sürecinde öğrendiğini ve hatalarını azalttığını gösterir. Bununla birlikte, değerlendirme kaybı eğitim kaybı ile tamamen paralel bir düşüş göstermemiştir. Bu durum, başlangıçta modelin eğitim seti üzerindeki performansının, değerlendirme seti üzerindeki performansını tam olarak yansıtmadığını göstermektedir.


Eğitim başarısı genel olarak artış gösterirken, değerlendirme başarısı daha değişken bir trend izlemiştir. Özellikle, 13. fazda, modelin değerlendirme başarısı önemli ölçüde düşmüş ve değerlendirme kaybı önemli ölçüde artmıştır.

Bu süreçte en iyi performansı gösteren faz, değerlendirme seti üzerindeki doğruluğun en yüksek olduğu, yani modelin genelleme kabiliyetinin en güçlü olduğu fazdır. Bu

durumda, 6. ve 9. faz, %97.66 doğruluk oranı ile modelin değerlendirme seti üzerinde en iyi performans gösterdiği fazdır.

Buna rağmen, 6. fazın değerlendirme kaybı bazı diğer fazlardan daha yüksektir. Modelin genel performansını değerlendirirken hem başarı hem de kayıp değerlerinin dikkate alınması önemlidir. Bu durumda, en düşük değerlendirme kaybına sahip olan faz 9. fazdır. Bu nedenle en iyi öğrenim gösteren faz 9. faz olarak belirlenmiştir.

InceptionV4 modeli için modelin hiç görmediği test verisindeki sınıflandırma sonuçları şekilde verilmiştir.



Şekil 4.16. InceptionV4 modeli sınıflandırma matrisi

- Glioma sınıfında, modelin 276 doğru sınıflandırma yapmış ve 22 Meningioma ile 2 Pituitary'yi yanlışlıkla Glioma olarak sınıflandırdığı görülmüştür.
- Meningioma sınıfında, modelin 300 doğru sınıflandırma yapmış ve 2 Glioma, 1 Notumor ve 3 Pituitary'yi yanlışlıkla Meningioma olarak sınıflandırdığı görülmüştür.
- Notumor sınıfında, modelin 404 doğru sınıflandırma yapmış ve sadece 1 Meningioma'yı yanlışlıkla Notumor olarak sınıflandırdığı görülmüştür.
- Pituitary sınıfında, modelin 300 doğru sınıflandırma yapmış ve hiçbir yanlış sınıflandırma yapmadığı görülmüştür.
- Model genel olarak iyi bir performans sergilemiştir.

InceptionV4 modeli için test veri seti üzerinde yapılan sınıflandırma sonuçlarının tablosu verilmiştir.

Çizelge 4.15. InceptionV4 sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Glioma	0.99	0.92	0.96	300
Meningioma	0.93	0.98	0.95	306
Notumor	1	1	1	405
Pituitary	0.98	1	0.99	300
Doğruluk			0.98	1311
Makro Ort.	0.98	0.97	0.97	1311
Ağırlıklı Ort.	0.98	0.98	0.98	1311

"Glioma" tümör türünü belirlemede, model %99'luk bir hassasiyet ve %92'lik bir duyarlılık sergilemiştir. F1 skoru ise %96 olarak hesaplanmıştır. Bu, modelin "glioma" türündeki tümörleri çok yüksek bir doğrulukla tanımladığını göstermektedir.

"Meningioma" tümör türünde ise, modelin hassasiyeti %93 iken, duyarlılığı %98'dir. Bu durum, modelin "meningioma" türündeki tümörleri neredeyse mükemmel bir doğrulukla tahmin ettiğini gösterir. Bu tür için F1 skoru %95 olarak hesaplanmıştır.

"Notumor" sınıfında, model %100'lik hem hassasiyet hem de duyarlılık göstermiştir. Bu, modelin tümör içermeyen durumları mükemmel bir doğrulukla tahmin ettiğini gösterir. F1 skoru da bu sınıf için %100 olarak hesaplanmıştır.

"Pituitary" tümör türünde, model %98'lik bir hassasiyet ve %100'lük bir duyarlılık sergilemiştir. F1 skoru, bu tür için %99 olarak hesaplanmıştır.

Modelin genel doğruluğu %98 olarak belirlenmiştir. Ayrıca, makro ortalama değerlerine bakıldığında, hassasiyetin %98, duyarlılığın %97 ve F1 skorunun %97 olduğu görülmüştür. Ağırlıklı ortalama değerlerine bakıldığında ise, hassasiyetin %98, duyarlılığın %98 ve F1 skorunun %98 olduğu belirlenmiştir.

4.5.1.8. DenseNet Modelinin ImageNet Ağırlıklarıyla Eğitimi

DenseNet modelinin eğitim sırasında elde ettiği değerler tabloda gösterilmektedir.


Çizelge 4.16. DenseNet modeli eğitim süreci

DenseNet	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	0.5031	0.8324	1.6336	0.5818
	2	0.3194	0.8954	0.9317	0.7243
	3	0.2495	0.9176	1.5485	0.6928
	4	0.2084	0.9314	0.4261	0.8808
	5	0.1559	0.951	0.1366	0.9638
	6	0.1491	0.9491	0.2062	0.9252
	7	0.1116	0.9658	0.7752	0.7769
	8	0.119	0.9619	0.2107	0.9276
	9	0.0892	0.9691	0.2198	0.9252
	10	0.0798	0.9741	0.439	0.8937

Başlangıçta, 1. fazda modelin doğruluk oranı %83.24 ve değerlendirme setinde başarı oranı %58.18 olarak gözlemlenmiştir. Bu modelin eğitim setine göre iyi ancak değerlendirme setine göre daha kötü performans sergilediğini göstermektedir. Kayıp değerleri de bu duruma paralel olarak yüksek çıkmaktadır. Ancak, 5. faza geldiğimizde modelin performansı önemli ölçüde artmakla birlikte, doğruluk oranı %95.1'e ve değerlendirme setinde değerlendirme başarıları %96.38'e gelmektedir. Bu, modelin bu fazda hem eğitim hem de değerlendirme setinde yüksek performans sergilediğini göstermektedir.

Sonraki fazlarda, modelin performansı dalgalı bir seyir izlemektedir. Özellikle, 7. fazda değerlendirme setindeki başarı oranı %77.69'a düşmüştür, bu da modelin genelleme yeteneğinin belirli bir noktada düştüğünü göstermektedir.

InceptionV4 modeli için modelin hiç görmediği test verisindeki sınıflandırma sonuçları şekilde verilmiştir.



Şekil 4.17. DenseNet modeli sınıflandırma matrisi

- Glioma sınıfında, model 212 doğru sınıflandırma yapmış ve 37 Meningioma, 21 Notumor ve 30 Pituitary'yi yanlışlıkla Glioma olarak sınıflandırmıştır.
- Meningioma sınıfında, model 224 doğru sınıflandırma yapmış ve 3 Glioma, 49 Notumor ve 30 Pituitary'yi yanlışlıkla Meningioma olarak sınıflandırmıştır.
- Notumor sınıfında, model 403 doğru sınıflandırma yapmış ve sadece 1 Meningioma ve 1 Pituitary'yi yanlışlıkla Notumor olarak sınıflandırmıştır.
- Pituitary sınıfında, model 289 doğru sınıflandırma yapmış ve sadece 11 Meningioma'yı yanlışlıkla Pituitary olarak sınıflandırmıştır.
- Model, Notumor ve Pituitary sınıflarını genellikle iyi belirlerken, Glioma ve Meningioma sınıflarında daha fazla hata yapıyor.
- Özellikle, modelin Glioma ve Meningioma sınıflarını diğer tüm sınıflarla karıştırma eğiliminde olduğu görülüyor.

InceptionV4 modeli için test veri seti üzerinde yapılan sınıflandırma sonuçlarının tablosu verilmiştir.

Çizelge 4.17. DenseNet modeli sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Glioma	0.99	0.71	0.82	300
Meningioma	0.82	0.73	0.77	306
Notumor	0.85	1	0.92	405
Pituitary	0.83	0.96	0.89	300
Doğruluk			0.86	1311
Makro Ort.	0.87	0.85	0.85	1311
Ağırlıklı Ort.	0.87	0.86	0.86	1311

"Glioma" tümör türü için, model %99 hassasiyet ve %71 duyarlılık oranlarına sahiptir. Bu durum, modelin "glioma" türündeki tümörleri doğru bir şekilde tanıma yeteneğini gösterir, ancak duyarlılık oranı daha düşüktür. Bu, modelin aslında "glioma" olan bazı durumları doğru bir şekilde sınıflandıramadığını gösterir. "Glioma" için hesaplanan F1 skoru %82'dir, bu da modelin bu türdeki tümörlerin sınıflandırılmasında hassasiyet ve duyarlılık arasında dengeli bir performans sergilemediğini göstermektedir.

"Meningioma" tümör türünde ise, model %82 hassasiyet ve %73 duyarlılık oranlarına sahiptir. F1 skoru %77 olarak hesaplanmıştır, bu da modelin "meningioma" türündeki tümörlerin sınıflandırılmasında dengeli bir performans sergilediğini, ancak yine de geliştirme alanı olduğunu göstermektedir.

"Notumor" sınıfında, model %85 hassasiyet ve %100 duyarlılık oranlarına ulaşmıştır. Bu, modelin tümör içermeyen durumları mükemmel bir şekilde tahmin ettiğini göstermektedir. Bu sınıf için hesaplanan F1 skoru %92'dir.

"Pituitary" tümör türünde, model %83 hassasiyet ve %96 duyarlılık oranlarına sahiptir. F1 skoru da %89'dur, bu da modelin "pituitary" tümör türünde dengeli ve yüksek bir performans sergilediğini gösterir.

Modelin genel dođruluk oranı %86'tır. Bu, modelin tüm tümör tiplerini genel olarak dođru bir şekilde tahmin ettiđini gösterir. Ayrıca, hassasiyet, duyarlılık ve F1 skoru için makro ve ađırlıklı ortalama deđerlerin her ikisi de %87 ve %86 olarak hesaplanmıştır.

Bu sonuçlar, modelin genel olarak iyi bir performans sergilediđini, tüm tümör türlerini etkili bir şekilde sınıflandırabildiđini göstermektedir. Ancak "glioma" ve "meningioma" türlerindeki düşük duyarlılık oranları, modelin bu türlerdeki tümörleri bazen kaçırabileceđini ve bu nedenle bu alanlarda geliştirme yapmanın önemli olduđunu göstermektedir.

4.5.2. 44 Sınıflı Veri Seti Deneysel Sonuçları

4.5.2.1. ResNet Modelinin ImageNet Ağırlıklarıyla Eğitimi

ResNet modelinin eğitim sırasında elde ettiği değerler tabloda gösterilmektedir.

Çizelge 4.18. ResNet modeli eğitim süreci

ResNet	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	3.5083	0.1292	43.6818	0.0119
	2	2.2938	0.3181	13.0038	0.0924
	3	1.5508	0.4807	2.5710	0.3517
	4	1.0730	0.5939	1.8623	0.4575
	5	0.6739	0.7145	1.3252	0.6334
	6	0.4789	0.7912	2.2533	0.4143
	7	0.3456	0.8419	1.0558	0.7154
	8	0.3564	0.8421	1.7390	0.5618
	9	0.2273	0.8918	2.1536	0.4635
	10	0.1267	0.9393	0.5513	0.8390
	11	0.1595	0.9307	1.2297	0.6930
	12	0.3570	0.8624	0.6587	0.8256
	13	0.1564	0.9343	0.4276	0.8778
	14	0.0456	0.9779	0.3137	0.9091
	15	0.0169	0.9905	0.2801	0.9076
	16	0.0168	0.9903	0.2965	0.9165
	17	0.0115	0.9934	0.2495	0.9374
	18	0.1010	0.9593	8.7897	0.2250
	19	0.4286	0.8390	1.4137	0.6334
	20	0.1246	0.9417	1.4573	0.6632
	21	0.1798	0.9230	0.7247	0.7914
	22	0.0526	0.9727	0.3196	0.9106

İlk fazlarda, modelin eğitim kaybı oldukça yüksekken, eğitim başarısı düşük. Ancak fazlar ilerledikçe, modelin eğitim kaybı belirgin şekilde azalırken, eğitim başarısı sürekli olarak artar. Bu durum, modelin eğitim verilerini öğrenmekte olduğunu ve tahminlerinin giderek daha doğru hale geldiğini gösterir.

- Astrocitoma T1, Carcinoma T1 ve T1C+, Ependimoma T1, Ganglioglioma tüm tiplerleri, Germinoma T1, Glioblastoma T1 ve T1C+, Meduloblastoma T1, Oligodendroglioma T1 ve T1C+, Papiloma tüm tiplerleri, Schwannoma T1 ve Tuberculoma T1 ve T1C+ sınıflarında tümörler %100 hassasiyetle tanımlanmış. Bu, modelin bu tür tümörleri mükemmel bir şekilde tanıdığını gösterir.
- Ancak, Granuloma T2 sınıfında modelin hiçbir tümörü doğru bir şekilde sınıflandıramadığını görüyoruz. Bu, belki de modelin bu tür tümörler üzerinde daha fazla eğitim alması gerektiğini gösteriyor.
- Genel olarak, modelin doğruluk oranı %94, yani 671 vakadan 630'unu doğru sınıflandırmış. Bu, modelin genel performansının oldukça iyi olduğunu göstermektedir. Ancak, bazı tümör tiplerinde (örneğin Granuloma T2, Ependimoma T2 ve diğerleri) hassasiyet oranları düşük olduğundan, bu tümör tiplerini daha iyi sınıflandırabilmek için modelin eğitimi üzerinde çalışılması gerekebilir.

Çizelge 4.19. ResNet modeli sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Doğruluk			0.94	671
Makro Ort.	0.94	0.91	0.92	671
Ağırlıklı Ort.	0.95	0.94	0.94	671

Gözden geçirdiğimiz metriklere göre, sınıflandırma modelinin performansı oldukça yüksek görünüyor. Genel doğruluk %94, bu da modelin tahminlerinin büyük bir çoğunluğunu doğru bir şekilde yaptığını gösteriyor. Bu değer, 671 örnek üzerinde yapılan test sonuçlarından alınmış ve modelin %94 oranında doğru sınıflandırma yaptığını gösteriyor.

Ayrıca, makro-ortalama ve ağırlıklı-ortalama metriklerine bakılacak olursa; hassasiyet, duyarlılık ve F1-Skor değerleri de oldukça yüksektir. Bu metriklerin her biri, modelin farklı sınıflar arasında ne kadar iyi bir iş çıkardığını değerlendirir. Özellikle, F1-Skor değeri bir modelin hassasiyeti ve duyarlılığı arasındaki dengeyi gösterir ve genellikle daha dengeli bir performans ölçütüdür. Bu durumda, hem makro hem de ağırlıklı ortalama

F1-Skor deęerleri %92 ve %94'tür. Bu, modelin hem pozitif hem de negatif sınıflardaki örneklere oldukça iyi bir şekilde sınıflandırdığını gösterir.

4.5.2.2. ResNet Modelinin ImageNet Aęırlıkları Olmadan Eęitimi


Çizelge 4.20. ResNet modeli eęitim süreci

ResNet	Faz Sayısı	Eęitim Kaybı	Eęitim Başarısı	Deęerleme Kaybı	Deęerleme Başarısı
	1	4.3345	0.0436	7.2339	0.0611
	2	3.6376	0.0788	3.7666	0.0596
	3	3.3854	0.1019	5.4241	0.0402
	4	3.2428	0.1211	4.4394	0.1028
	5	2.8487	0.1707	5.9172	0.0671
	6	2.8802	0.1760	3.6011	0.1505
	7	2.9249	0.1773	9.0827	0.1103
	8	2.4784	0.2509	4.6073	0.1371
	9	2.1799	0.3181	2.5898	0.3085
	10	1.9448	0.3754	3.5134	0.2861
	11	1.7167	0.4334	5.6732	0.2250
	12	1.5325	0.4652	1.7091	0.4784
	13	1.2091	0.5427	1.5711	0.5484
	14	1.0780	0.5779	1.5640	0.5618
	15	0.9129	0.6317	1.7030	0.5618
	16	0.7593	0.6882	1.4313	0.6215
	17	0.6937	0.7132	1.3556	0.6379
	18	0.5198	0.7657	0.6779	0.7988
	19	0.4338	0.7920	1.5578	0.6545
	20	0.5492	0.7709	1.1858	0.7124
	21	0.4109	0.8167	0.9346	0.7481
	22	0.3524	0.8316	0.7787	0.7765
	23	0.2704	0.8742	2.5496	0.6230

Eęitim verilerine bakıldığında, ilk başta modelin performansının oldukça düşük olduęu görölüyor İlk fazda, modelin başarı oranı sadece 0.0436 ve deęerleme veri setinde 0.0611. Ancak, fazlar ilerledikçe modelin performansında genel bir artış trendi gözlenmektedir.

Bu, modelin eğitim verilerini daha iyi öğrendiğini ve genellenebilirliğini artırdığını gösterir.

Faz 18'e geldiğimizde, modelin eğitim başarı oranı 0.7657'ye, değerlendirme başarı oranı ise 0.7988'e çıkmış durumda. Bu, modelin eğitim verilerinde ve değerlendirme verilerinde yüksek bir başarı oranına ulaştığını gösteriyor. Ancak, 23. fazda modelin değerlendirme başarı oranı 0.6230'a düşmektedir. Bu, modelin aşırı uyum yaşadığını ve eğitim verilerini ezberlemeye başladığını göstermektedir. Bu nedenle eğitim kesilmektedir ve en iyi genellemeye sahip olan 18. faz modelin ağırlıklarının belirleyen faz olmaktadır.



Şekil 4.19. ResNet modeli sınıflandırma matrisi

- Astrocitoma T1, Ependimoma T2 ve Tuberculoma T2 gibi sınıflar, modelin bu türlerin örneklerini belirlemede zorlandığı gibi görünmektedir.
- Ependimoma T1C+, Ganglioglioma T1, Ganglioglioma T2, Germinoma T1, Germinoma T1C+, Glioblastoma T1, Neurocitoma T1C+ ve _NORMAL T1 gibi sınıflar model tarafından çok iyi sınıflandırılmıştır.
- Carcinoma T2 ve Glioblastoma T2 sınıfları da model tarafından etkili bir şekilde sınıflandırılmıştır.
- Ancak, Germinoma T2, Meduloblastoma T2, Meningioma T1 ve Neurocitoma T2 gibi sınıflar model tarafından yeterince iyi sınıflandırılmamış gibi görünmektedir.
- Genel olarak, modelin sınıflandırma performansı ortalamada iyi olarak değerlendirilebilir ancak bazı sınıflar diğerlerine göre daha düşük performans göstermiştir.

Çizelge 4.21. ResNet modeli sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Doğruluk			0.8	671
Makro Ort.	0.8	0.83	0.8	671
Ağırlıklı Ort.	0.83	0.8	0.8	671

Modelin genel performansı yüksek olup, başarı oranı %80'dir. Bu, modelin tüm sınıflamaların %80'ini doğru olarak gerçekleştirdiği anlamına gelmektedir.

Ancak, modelin makro ortalaması ve ağırlıklı ortalaması değerlendirildiğinde, modelin bazı sınıflarda daha iyi performans göstermiş olabileceği sonucuna ulaşılabilir. Makro ortalama değerleri, hassasiyet ve F1 skoru için %80, duyarlılık oranı için %83'tür. Bu değerler, modelin her bir sınıfta neredeyse benzer bir performans gösterdiğini, ancak duyarlılık oranında hafif bir artış olduğunu göstermektedir.

Öte yandan, ağırlıklı ortalama değerlerine bakıldığında, hassasiyet ve F1 skoru için %83, duyarlılık oranı için %80 elde edilmiştir. Bu durum, modelin daha çok örneği olan sınıflarda daha iyi performans gösterdiğini düşündürmektedir.

Sonuç olarak, modelin genel performansı yüksek olup, tüm sınıflar içerisinde örneklerin %80'ini doğru sınıflandırabilmiştir. Ancak, bazı sınıflar üzerinde daha yüksek bir başarıya ulaşılmıştır. Özellikle, modelin duyarlılık oranı genel olarak hassasiyet ve F1 skoru değerlerine göre biraz daha yüksek çıkmıştır. Bu durum, modelin pozitif sınıfları tespit etme yeteneğinin güçlü olduğunu göstermektedir.

4.5.2.3. MobileNet Modelinin ImageNet Ağırlıklarıyla Eğitimi

Çizelge 4.22. MobileNet modeli eğitim süreci

ResNet	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	2.6292	0.3325	2.8819	0.3145
	2	1.2593	0.6028	2.5527	0.3845
	3	0.8555	0.7082	1.3477	0.6334
	4	0.5003	0.8096	1.4756	0.5946
	5	0.5023	0.8114	1.9908	0.5395
	6	0.3653	0.8513	1.6319	0.6289
	7	0.2674	0.8871	0.5466	0.8554
	8	0.1548	0.9267	1.068	0.6975
	9	0.3438	0.8729	1.0681	0.7601
	10	0.3326	0.8716	1.286	0.7094
	11	0.2467	0.9146	0.5322	0.851
	12	0.2727	0.9025	0.4837	0.8689
	13	0.1276	0.9409	0.7106	0.8405
	14	0.1396	0.9422	0.5271	0.8838
	15	0.1956	0.9291	0.8767	0.7988
	16	0.2471	0.9107	1.4378	0.7139
	17	0.1569	0.9388	1.1972	0.7735

Eğitimin ilk fazında, modelin performansı genel olarak düşük başlamıştır. Ancak faz ilerledikçe modelin eğitim verisi üzerindeki başarı oranı artmaya başlamaktadır. 3. fazda, modelin değerlendirme seti üzerindeki başarı oranı büyük bir artış göstererek yaklaşık 0.63'e çıkıyor. Bu, modelin genelleştirme yeteneğinin gelişmeye başladığını göstermektedir.

- Tabloya göre, en iyi sınıflandırılan sınıflar Ganglioglioma T1 ve T1C+, Germinoma T2, Glioblastoma T1C+ ve T2, Oligodendroglioma T1 ve T1C+, Schwannoma T1 ve T2 sınıflarıdır.
- Bununla birlikte, modelin en kötü performans gösterdiği sınıflar da mevcuttur. Örneğin, Granuloma T2'de model, hiçbir tümörü doğru bir şekilde sınıflandıramamıştır. Ependimoma T1C+ ve Tuberculoma T2'deki performans da nispeten düşüktür.

Çizelge 4.23. MobileNet sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Doğruluk			0.88	671
Makro Ort.	0.87	0.87	0.85	671
Ağırlıklı Ort.	0.92	0.88	0.89	671

Bu tabloya göre sınıflandırma modelinin performansı genel olarak tatmin edici olarak değerlendirilebilir. Özellikle, modelin genel başarı oranı %88 olarak belirlenmiştir, bu da modelin tahminlerinin büyük çoğunluğunu doğru şekilde yapabildiğini göstermektedir.

Makro ortalama değerleri hassasiyet ve duyarlılık için sırasıyla %87'dir. Bu, modelin pozitif olarak tahmin edilen durumların ve gerçekten pozitif olan durumların büyük bir kısmını doğru bir şekilde belirleyebildiğini gösterir. F1-Skorun %85 olması da hassasiyet ve duyarlılık arasında iyi bir denge olduğunu göstermektedir, bu nedenle model dengesiz bir veri seti üzerinde bile iyi performans gösterebilir.

Ağırlıklı ortalama değerler, hassasiyet için %92, duyarlılık ve F1-Skor için ise %88 ve %89'dur. Bu değerler, modelin her sınıfın örnek sayısını hesaba katarak bu metriklere ulaştığını gösterir.

4.5.2.4. DenseNet Modelinin ImageNet Ağırlıklarıyla Eğitimi

Çizelge 4.24. DenseNet modeli eğitim süreci

DenseNet	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	3.2953	0.1755	5.5028	0.1654
	2	2.3237	0.3110	2.4829	0.4426
	3	1.6856	0.4337	4.7986	0.2280
	4	1.3989	0.5101	2.0741	0.4516
	5	1.0732	0.5997	1.4809	0.5604
	6	0.8853	0.6554	1.9802	0.4948
	7	0.6806	0.7234	1.2173	0.6736
	8	0.5971	0.7610	2.3640	0.4486
	9	0.5778	0.7662	1.1891	0.6721
	10	0.4570	0.8022	0.9980	0.7183
	11	0.3818	0.8413	1.4891	0.6319
	12	0.3331	0.8487	1.0288	0.7273
	13	0.4473	0.8182	0.8682	0.7511
	14	0.2528	0.8868	0.8974	0.7630
	15	0.5273	0.7964	0.7730	0.8167
	16	0.2134	0.8965	0.3916	0.8927
	17	0.1929	0.9070	0.7448	0.8092
	18	0.2943	0.8708	0.7298	0.8241
	19	0.2730	0.8884	1.3409	0.6945
	20	0.1698	0.9207	0.6707	0.8197
	21	0.1788	0.9233	0.5248	0.8599

Eğitim kaybı, genellikle eğitim süreci boyunca azalıyor, bu da modelin eğitim veri setini daha iyi öğrendiğini gösteriyor. Özellikle, 1. fazdan 21. faza kadar olan süreçte, eğitim kaybı 3.2953'ten 0.1788'e düşüyor. Modelin öğrenme kapasitesinin yüksek olduğunu ve eğitim verilerini iyi bir şekilde öğrendiğini gösteriyor.

Bununla birlikte değerlendirme kaybı ve başarı, fazlar boyunca dalgalanma gösteriyor. Örneğin, 2. ve 4. fazlarda değerlendirme başarıları artarken, 3. fazda düşüş gösteriyor.

- Diđer yandan, Granuloma T2 ve Granuloma T1 sınıfları, model tarafından en kötü sınıflandırılan sınıflardır. Özellikle Granuloma T2'de model, hiçbir tümörü doğru bir şekilde sınıflandıramamıştır.

Çizelge 4.25. DenseNet modeli sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Doğruluk			0.89	671
Makro Ort.	0.89	0.86	0.86	671
Ağırlıklı Ort.	0.90	0.89	0.89	671

4.5.2.5. InceptionV4 Modelinin ImageNet Ağırlıklarıyla Eğitimi

Çizelge 4.26. InceptionV4 modeli eğitim süreci

InceptionV4	Faz Sayısı	Eğitim Kaybı	Eğitim Başarısı	Değerleme Kaybı	Değerleme Başarısı
	1	2.8538	0.2304	5.0275	0.1997
	2	1.6876	0.4589	2.3743	0.4188
	3	0.9042	0.684	1.1828	0.6692
	4	0.5225	0.7964	0.9162	0.7258
	5	0.2535	0.8976	1.8995	0.5842
	6	0.2299	0.9128	0.5221	0.842
	7	0.0953	0.9548	0.3614	0.8912
	8	0.054	0.9782	0.4075	0.8912
	9	0.0525	0.9761	0.3562	0.8942
	10	0.2255	0.9233	6.149	0.3666
	11	0.3486	0.8807	1.1196	0.7332
	12	0.1095	0.9582	0.888	0.7809
	13	0.1465	0.9511	0.3822	0.9001
	14	0.0956	0.9598	0.3382	0.8897
	15	0.024	0.9879	0.1816	0.9478
	16	0.0134	0.9919	0.1973	0.9493
	17	0.0323	0.9832	0.427	0.8852
	18	0.025	0.9853	0.3247	0.9121
	19	0.0142	0.9926	0.2150	0.9389
	20	0.0073	0.9947	0.1708	0.9538
	21	0.0063	0.9950	0.1304	0.9627
	22	0.1574	0.9441	8.8791	0.2131
	23	0.2994	0.8913	0.4145	0.8852
	24	0.1068	0.9551	0.5809	0.8659
	25	0.0348	0.9827	0.2403	0.9314
	26	0.0700	0.9711	0.5264	0.8644

Fazların ilk dört aşamasında, modelin eğitim seti ve değerlendirme seti üzerindeki performansı belirgin şekilde gelişmiştir. Bu, modelin temel özellikleri öğrenmeye başladığı ve bu bilgiyi genelleştirmeye başladığı anlamına gelmektedir.

T1C+, Meduloblastoma T2, Meningioma T2, Oligodendroglioma T1, Oligodendroglioma T1C+, Oligodendroglioma T2, Papiloma T1, Schwannoma T1, Tuberculoma T1, _NORMAL T1 ve _NORMAL T2'dir. Bu sınıfların tamamı, hassasiyet ve duyarlılık metriklerinde %100'lük bir performans göstermiştir, yani model bu sınıfları mükemmel şekilde sınıflandırmıştır.

- Öte yandan, bazı sınıflarda modelin performansı düşmüştür. Bunlardan biri Ganglioglioma T1 ve Ganglioglioma T1C+'dır. Her ne kadar bu sınıflar için duyarlılık oranı %100 olsa da, hassasiyet oranı yalnızca %50'dir. Bu, modelin bu sınıfları doğru bir şekilde tanıma konusunda bazı zorluklar yaşadığını göstermektedir. Benzer şekilde, Granuloma T2 sınıfı için hem hassasiyet hem de duyarlılık oranı %50'dir, bu da modelin bu sınıfı doğru bir şekilde sınıflandırmakta zorlandığını göstermektedir.

Çizelge 4.27. InceptionV4 modeli sınıflandırma raporu

	Hassasiyet	Duyarlılık	F1-Skor	Destek
Doğruluk			0.96	671
Makro Ort.	0.93	0.95	0.93	671
Ağırlıklı Ort.	0.97	0.96	0.96	671

Sınıflandırma model, genel başarı değeriyle %96'lık etkileyici bir başarı göstermektedir. Bu, modelin problemi çözme konusunda son derece güvenilir ve etkili olduğunu gösterir.

Makro ortalamalar, modelin hassasiyet ve duyarlılık performansının da yüksek olduğunu belirtir. Hassasiyetin %93 ve duyarlılığın %95 olması, modelin doğru pozitif tahminlerde ve gerçek pozitif durumları belirlemede başarılı olduğunu gösterir. F1-Skoru da %93 olarak hesaplanmıştır ki bu, hassasiyet ve duyarlılık arasında yüksek bir denge olduğunu işaret eder. Bu durum, dengesiz veri setleri üzerinde bile modelin güçlü bir performans sergileyebileceğini belirtir.

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada iki farklı veri seti üzerinde 5 farklı mimari, 2 farklı yaklaşım ile incelenmiştir. Bu 5 mimari, ResNet, EfficientNet, MobileNet, DenseNet ve InceptionV4 mimarileri olmuştur. Uygulanan 2 farklı yaklaşım ise kullanılan her bir mimarinin öğrenme aktarımı süreçlerine sadık kalarak “ImageNet” ağırlıklarıyla eğitildiği durumlar, bir de daha az başarıya ulaşmasını beklediğimiz “ImageNet” ağırlıkları kullanılmadan eğitilen mimarilerdir.

Çizelge 5.1. 4 sınıflı veri kümesi için performans karşılaştırması

Model	Hassasiyet / Ağırlıklı Ort.	Duyarlılık / Ağırlıklı Ort.	F1-Skor / Doğruluk
ResNet50 – ImageNet	0.97	0.97	0.97
ResNet50 – Rastgele Ağırlıklar	0.93	0.93	0.93
EfficientNet – ImageNet	0.98	0.98	0.98
EfficientNet – Rastgele Ağırlıklar	0.96	0.95	0.95
MobileNet – ImageNet	0.97	0.97	0.97
MobileNet – Rastgele Ağırlıklar	0.71	0.66	0.66
InceptionV4 – ImageNet	0.98	0.98	0.98
DenseNet – ImageNet	0.87	0.86	0.86

Dört farklı sınıfı barındıran (Glioma, Meningioma, NoTumor, Pituitary) veri setimiz üzerinde yaptığımız çalışmada ResNet modeli, ImageNet ağırlıklarıyla eğitildiğinde oldukça iyi sonuçlar göstermiştir. Özellikle NoTumor ve Pituitary sınıflarında yüksek başarıyla sınıflandırma yapmıştır. Ancak, Glioma ve Meningioma sınıfları ayırma konusunda biraz düşük performans göstermiştir. ImageNet ağırlıkları kullanılmadığında, bu modelin performansı düşmüştür ve tüm sınıflarda daha düşük hassasiyet değerleri elde edilmiştir.

EfficientNetB1 modeli, ResNet'ten daha iyi performans göstermiştir ve ImageNet ağırlıklarıyla eğitildiğinde sınıflar arasında daha az karışıklık göstermiştir. Bu model, Glioma sınıfında %100 başarı elde ederken, diğer sınıflarda da yüksek başarı oranlarına ulaşmıştır. ImageNet ağırlıkları olmadan bu modelin performansı azalsa da, oldukça iyi sonuçlar elde edilmiştir.

MobileNet modeli, genel olarak iyi sonuçlar vermiştir, ancak Glioma ve Meningioma sınıfları arasında bir miktar karışıklık yaşanmıştır. ImageNet ağırlıklarıyla eğitildiğinde, özellikle NoTumor sınıfında yüksek başarı elde edilmiştir. Ancak, ImageNet ağırlıkları olmadan bu modelin performansı önemli ölçüde düşmektedir.

Genel olarak değerlendirildiğinde, EfficientNetB1 modelinin, özellikle ImageNet ağırlıklarıyla eğitildiğinde, beyin tümörü sınıflandırması için en uygun model olduğunu gözlemleyebiliriz. ResNet modeli de kabul edilebilir performans gösterirken, MobileNet modeli, ImageNet ağırlıkları olmadan önemli ölçüde daha düşük performansa sahip olduğu gözlemlenmiştir. Bu sonuçlar, beyin tümörü sınıflandırması için kullanılacak derin öğrenme modellerinin seçimine ışık tutabilir. ImageNet ağırlıklarının kullanımının, performansı genellikle artırdığı görülmektedir, bu yüzden önceden eğitilmiş ağırlıkları kullanmanın ileride de fayda yaratacağı söylenebilir.

Farklı derin öğrenme modelleri olan ResNet, MobileNet, DenseNet ve InceptionV4'ün bir veri seti üzerindeki performansları dikkate alındığında, her modelin kendine has avantaj ve dezavantajları bulunmaktadır. Veri seti, farklı türlerdeki tümörleri içeren tıbbi görüntülerden oluşuyor ve bu modellerin amacı bu tümörleri doğru bir şekilde sınıflandırmaktır.

Çizelge 5.2. 44 sınıflı veri seti için performans karşılaştırması

Model	Hassasiyet / Ağırlıklı Ort.	Duyarlılık / Ağırlıklı Ort.	F1-Skor / Doğruluk
ResNet50 – ImageNet	0.95	0.94	0.94
ResNet50 – Rastgele Ağırlıklar	0.83	0.80	0.80
MobileNet – ImageNet	0.92	0.88	0.88
InceptionV4 – ImageNet	0.97	0.96	0.96
DenseNet – ImageNet	0.90	0.89	0.89

ResNet modeli, ImageNet ağırlıklarıyla eğitildiğinde yüksek bir genel başarı oranına ulaşmakta ve bazı tümör türlerinde mükemmel sonuçlar elde etmektedir. Ancak,

Granuloma T2 gibi bazı spesifik sınıflarda başarısız oluyor. ImageNet ağırlıkları olmadan eğitildiğinde ise genel başarı oranı düşmektedir.

MobileNet ve DenseNet modelleri benzer şekilde, ImageNet ağırlıklarıyla eğitildiklerinde iyi genel performans gösterirken, bazı spesifik sınıflarda zorlandıkları gözlemlenmektedir. MobileNet, hafif bir yapıya sahip olduğu için, daha az hesaplama kaynağı gerektirir, ancak DenseNet, bazı sınıflarda daha iyi sınıflandırma sonuçları sunabilir.

InceptionV4, tüm modeller arasında en yüksek genel başarı oranına sahip olup, çoğu sınıfta mükemmel sınıflandırma sonuçları elde etmektedir. Ancak, bu model de bazı spesifik sınıflarda zorlanmaktadır.

Birlikte değerlendirildiğinde, bu modellerin hepsi kendi içinde değerlidir ve spesifik ihtiyaçlara göre seçim yapmak önemlidir. Örneğin, hesaplama kaynaklarının sınırlı olduğu durumlarda MobileNet tercih edilebilirken, daha yüksek genel başarı oranına öncelik veren senaryolarda InceptionV4 daha uygun olabilir. Ayrıca, modellerin zayıf olduğu alanlarda performansını artırmak için veri kaynağı artırılması ve çeşitlendirilmesi gibi yöntemler düşünülebilir. Özellikle tıbbi görüntü sınıflandırması gibi kritik uygulamalarda, modellerin kombinasyonunu kullanmak, daha sağlam ve güvenilir sonuçlar elde etmek açısından değerli olabilir.

KAYNAKLAR

- [1] G.S. Tandel, A. Balestrieri, T. Jujaray, N.N. Khanna, L. Saba, J.S. Suri, Multiclass magnetic resonance imaging brain tumor classification using artificial intelligence paradigm, *Computers in Biology and Medicine*, 122 (2020) 103804.
- [2] A. Mondal, V.K. Shrivastava, A novel Parametric Flatten-p Mish activation function based deep CNN model for brain tumor classification, *Computers in Biology and Medicine*, 150 (2022) 106183.
- [3] R. Vankdothu, M.A. Hameed, Brain tumor MRI images identification and classification based on the recurrent convolutional neural network, *Measurement: Sensors*, 24 (2022) 100412.
- [4] Y. Sun, C. Wang, A computation-efficient CNN system for high-quality brain tumor segmentation, *Biomedical Signal Processing and Control*, 74 (2022) 103475.
- [5] R. Vankdothu, M.A. Hameed, Brain tumor segmentation of MR images using SVM and fuzzy classifier in machine learning, *Measurement: Sensors*, 24 (2022) 100440.
- [6] A. Kazemi, M.E. Shiri, A. Sheikahmadi, Classifying tumor brain images using parallel deep learning algorithms, *Computers in Biology and Medicine*, 148 (2022) 105775.
- [7] K.R.M. Fernando, C.P. Tsokos, Deep and statistical learning in biomedical imaging: State of the art in 3D MRI brain tumor segmentation, *Information Fusion*, (2022).
- [8] B. Machado Pacheco, G. de Souza e Cassia, D. Silva, Towards fully automated deep-learning-based brain tumor segmentation: is brain extraction still necessary?, *arXiv e-prints*, (2022) arXiv: 2212.07497.
- [9] M. Havaei, A. Davy, D. Warde-Farley, A. Biard, A. Courville, Y. Bengio, C. Pal, P.-M. Jodoin, H. Larochelle, Brain tumor segmentation with deep neural networks, *Medical image analysis*, 35 (2017) 18-31.
- [10] R. Vankdothu, M.A. Hameed, H. Fatima, A brain tumor identification and classification using deep learning based on CNN-LSTM method, *Computers and Electrical Engineering*, 101 (2022) 107960.
- [11] K. Dang, T. Vo, L. Ngo, H. Ha, A deep learning framework integrating MRI image preprocessing methods for brain tumor segmentation and classification, *IBRO Neuroscience Reports*, 13 (2022) 523-532.

- [12] R.S. Devi, B. Perumal, M.P. Rajasekaran, A hybrid deep learning based brain tumor classification and segmentation by stationary wavelet packet transform and adaptive kernel fuzzy c means clustering, *Advances in Engineering Software*, 170 (2022) 103146.
- [13] M.A. Naser, M.J. Deen, Brain tumor segmentation and grading of lower-grade glioma using deep learning in MRI images, *Computers in biology and medicine*, 121 (2020) 103758.
- [14] M. Jiang, F. Zhai, J. Kong, A novel deep learning model DDU-net using edge features to enhance brain tumor segmentation on MR images, *Artificial Intelligence in Medicine*, 121 (2021) 102180.
- [15] L. Ma, F. Zhang, End-to-end predictive intelligence diagnosis in brain tumor using lightweight neural network, *Applied Soft Computing*, 111 (2021) 107666.
- [16] S. Abirami, G.P. Venkatesan, Deep learning and spark architecture based intelligent brain tumor MRI image severity classification, *Biomedical Signal Processing and Control*, 76 (2022) 103644.
- [17] C. Tang, B. Li, J. Sun, S.-H. Wang, Y.-D. Zhang, GAM-SpCaNet: gradient awareness minimization-based spinal convolution attention network for brain tumor classification, *Journal of King Saud University-Computer and Information Sciences*, (2023).
- [18] F. Zulfiqar, U.I. Bajwa, Y. Mehmood, Multi-class classification of brain tumor types from MR images using EfficientNets, *Biomedical Signal Processing and Control*, 84 (2023) 104777.
- [19] A. Anaya-Isaza, L. Mera-Jiménez, L. Verdugo-Alejo, L. Sarasti, Optimizing MRI-based brain tumor classification and detection using AI: A comparative analysis of neural networks, transfer learning, data augmentation, and the cross-transformer network, *European Journal of Radiology Open*, 10 (2023) 100484.
- [20] H. Mehnatkesh, S.M.J. Jalali, A. Khosravi, S. Nahavandi, An intelligent driven deep residual learning framework for brain tumor classification using MRI images, *Expert Systems with Applications*, 213 (2023) 119087.
- [21] I. Goodfellow, Y. Bengio, A. Courville, *Deep learning*, MIT press 2016.
- [22] M.H. Hassoun, *Fundamentals of artificial neural networks*, MIT press 1995.
- [23] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (1998) 2278-2324.
- [24] A. Krizhevsky, I. Sutskever, G.E. Hinton, Imagenet classification with deep convolutional neural networks, *Communications of the ACM*, 60 (2017) 84-90.

- [25] C. Nwankpa, W. Ijomah, A. Gachagan, S. Marshall, Activation functions: Comparison of trends in practice and research for deep learning, arXiv preprint arXiv:1811.03378, (2018).
- [26] D. Scherer, A. Müller, S. Behnke, Evaluation of pooling operations in convolutional architectures for object recognition, Artificial Neural Networks–ICANN 2010: 20th International Conference, Thessaloniki, Greece, September 15-18, 2010, Proceedings, Part III 20, Springer, 2010, pp. 92-101.
- [27] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, Dropout: a simple way to prevent neural networks from overfitting, The journal of machine learning research, 15 (2014) 1929-1958.
- [28] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, Imagenet large scale visual recognition challenge, International journal of computer vision, 115 (2015) 211-252.
- [29] D.P. Kingma, J. Ba, Adam: A method for stochastic optimization, arXiv preprint arXiv:1412.6980, (2014).
- [30] D.E. Rumelhart, G.E. Hinton, R.J. Williams, Learning representations by back-propagating errors, nature, 323 (1986) 533-536.
- [31] L. Bottou, Large-scale machine learning with stochastic gradient descent, Proceedings of COMPSTAT'2010: 19th International Conference on Computational Statistics Paris France, August 22-27, 2010 Keynote, Invited and Contributed Papers, Springer, 2010, pp. 177-186.
- [32] I. Sutskever, J. Martens, G. Dahl, G. Hinton, On the importance of initialization and momentum in deep learning, International conference on machine learning, PMLR, 2013, pp. 1139-1147.
- [33] J. Duchi, E. Hazan, Y. Singer, Adaptive subgradient methods for online learning and stochastic optimization, Journal of machine learning research, 12 (2011).
- [34] T. Tieleman, G. Hinton, Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude, COURSERA: Neural networks for machine learning, 4 (2012) 26-31.
- [35] X. Glorot, A. Bordes, Y. Bengio, Deep sparse rectifier neural networks, Proceedings of the fourteenth international conference on artificial intelligence and statistics, JMLR Workshop and Conference Proceedings, 2011, pp. 315-323.
- [36] Y. Bengio, P. Simard, P. Frasconi, Learning long-term dependencies with gradient descent is difficult, IEEE transactions on neural networks, 5 (1994) 157-166.

- [37] J.S. Bridle, Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition, *Neurocomputing: Algorithms, architectures and applications*, Springer, 1990, pp. 227-236.
- [38] A.L. Maas, A.Y. Hannun, A.Y. Ng, Rectifier nonlinearities improve neural network acoustic models, *Proc. icml*, Atlanta, Georgia, USA, 2013, pp. 3.
- [39] J. Bergstra, Y. Bengio, Random search for hyper-parameter optimization, *Journal of machine learning research*, 13 (2012).
- [40] Y. Bengio, P. Lamblin, D. Popovici, H. Larochelle, Greedy layer-wise training of deep networks, *Advances in neural information processing systems*, 19 (2006).
- [41] G. Montavon, G. Orr, K.-R. Müller, *Neural networks: tricks of the trade*, springer2012.
- [42] P. Ramachandran, B. Zoph, Q.V. Le, Searching for activation functions, *arXiv preprint arXiv:1710.05941*, (2017).
- [43] A.Y. Ng, Feature selection, L 1 vs. L 2 regularization, and rotational invariance, *Proceedings of the twenty-first international conference on Machine learning*, 2004, pp. 78.
- [44] S. Ruder, An overview of gradient descent optimization algorithms, *arXiv preprint arXiv:1609.04747*, (2016).
- [45] J. Yosinski, J. Clune, Y. Bengio, H. Lipson, How transferable are features in deep neural networks?, *Advances in neural information processing systems*, 27 (2014).
- [46] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, (2014).
- [47] B.H. Menze, A. Jakab, S. Bauer, J. Kalpathy-Cramer, K. Farahani, J. Kirby, Y. Burren, N. Porz, J. Slotboom, R. Wiest, The multimodal brain tumor image segmentation benchmark (BRATS), *IEEE transactions on medical imaging*, 34 (2014) 1993-2024.
- [48] Y. Zhang, M. Brady, S. Smith, Segmentation of brain MR images through a hidden Markov random field model and the expectation-maximization algorithm, *IEEE transactions on medical imaging*, 20 (2001) 45-57.
- [49] R.C. Gonzalez, R. WOODS 3rd, Edition, *Digital Image Processing*. Upper Saddle River, USA: Prentice Hall, (2008).
- [50] A.K. Jain, *Fundamentals of digital image processing*, Prentice-Hall, Inc.1989.
- [51] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9.

- [52] L. Perez, J. Wang, The effectiveness of data augmentation in image classification using deep learning, arXiv preprint arXiv:1712.04621, (2017).
- [53] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770-778.
- [54] M. Sokolova, G. Lapalme, A systematic analysis of performance measures for classification tasks, Information processing & management, 45 (2009) 427-437.
- [55] G. Huang, D. Chen, T. Li, F. Wu, L. Van Der Maaten, K.Q. Weinberger, Multi-scale dense networks for resource efficient image classification, arXiv preprint arXiv:1703.09844, (2017).
- [56] A.G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, H. Adam, Mobilenets: Efficient convolutional neural networks for mobile vision applications, arXiv preprint arXiv:1704.04861, (2017).
- [57] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna, Rethinking the inception architecture for computer vision, Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 2818-2826.
- [58] N. Japkowicz, M. Shah, Evaluating learning algorithms: a classification perspective, Cambridge University Press 2011.
- [59] J. Davis, M. Goadrich, The relationship between Precision-Recall and ROC curves, Proceedings of the 23rd international conference on Machine learning, 2006, pp. 233-240.
- [60] C. Van Rijsbergen, Information retrieval: theory and practice, Proceedings of the joint IBM/University of Newcastle upon tyne seminar on data base systems, 1979.