



## Hibrit Aktarım Öğrenme Tekniklerini Kullanarak Beyin Tümörü Sınıflandırmasında Yeni Sonuçlar

Doğukan KALENDER<sup>1</sup> , Atahan ÖZTÜRK<sup>1</sup> , Ömer BİLGİN<sup>1</sup> , Durmuş Özkan ŞAHİN<sup>1\*</sup>

<sup>1</sup>Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Samsun, Türkiye

### Makale Bilgisi

Research article

Received: 14/06/2024

Revision: 26/10/2024

Accepted: 04/12/2024

### Anahtar Kelimeler

Derin öğrenme  
Beyin tümörü tespiti  
Aktarım öğrenmesi  
Görüntü işleme  
Tıbbi görüntü  
Tıbbi görüntü sınıflandırma

### Article Info

Araştırma makalesi

Başvuru: 14/06/2024

Düzelte: 26/10/2024

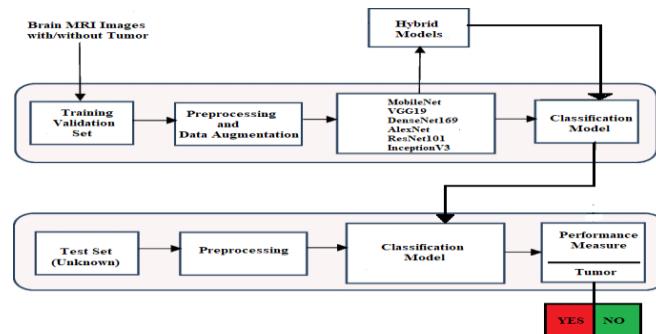
Kabul: 04/12/2024

### Keywords

Deep learning  
Brain tumor detection  
Transfer learning  
Image Processing  
Medical image  
Medical image classification

### Grafik Özeti (Graphical/Tabular Abstract)

Bu çalışma, beyin MR görüntülerinde tümör tespiti için aktarım öğrenmesi yöntemlerini kullanarak bir sistem geliştirmektedir. Çalışma adımları sırasıyla: veri kütmesinin hazırlanması, ön işleme, veri artırma, çeşitli aktarım öğrenme tekniklerinin uygulanması, bu tekniklerin birleştirilerek yeni modellerin geliştirilmesi ve test görüntüler üzerinde performans değerlendirmesidir. Şekil A, bu süreçlerin aşamalarını görsel olarak özetlemektedir. / This study develops a system for tumor detection in brain MRI images using transfer learning techniques. The steps involved are: dataset preparation, preprocessing, data augmentation, application of various transfer learning methods, combination of these methods to develop new models, and performance evaluation on test images. Figure A provides a visual summary of these stages.



**Şekil A:** Beyin Tümörü Tespit Sisteminin Yapısı / **Figure A:** Structure of Brain Tumor Detection System

### Önemli noktalar (Highlights)

- Çeşitli aktarım öğrenme teknikleri kullanılarak beyin MR görüntülerinde tümör tespiti yapıldı. / Tumor detection was performed on brain MRI images using various transfer learning techniques.
- VGG19 ve DenseNet169 modellerinin birleşimiyle oluşturulan hibrit model, %99.21 doğrulukla en yüksek başarıyı sağladı. / The hybrid model created by combining VGG19 and DenseNet169 achieved the highest performance with an accuracy of 99.21%.
- Hibrit modeller kullanılarak sınıflandırma başarısında %2'den fazla iyileşme elde edildi. / The use of hybrid models resulted in an improvement of over 2% in classification performance.

**Amaç (Aim):** Beyin MR görüntülerinde derin öğrenme tabanlı modeller kullanarak tümör tespiti yapmaktadır. Sınıflandırma doğruluğunu artırmak için hibrit modeller geliştirilmiştir. / To detect tumors using deep learning based models on brain MRI images. Hybrid models have been developed to increase the classification accuracy.

**Özgünlik (Originality):** Hibrit modellerin uygulanmasıyla, doğruluk oranında önemli bir artış sağlanarak literatüre katkı sağlanmıştır. / The application of hybrid models has resulted in a significant increase in accuracy, contributing to the existing literature.

**Bulgular (Results):** VGG19 ve DenseNet169 modellerinin birleşimiyle oluşturulan hibrit modelden %99.21 doğrulukla en iyi sınıflandırma başarımı elde edilmiştir. / The best classification performance with 99.21% accuracy was obtained from the hybrid model created by combining the VGG19 and DenseNet169 models.

**Sonuç (Conclusion):** Bu çalışmada, derin öğrenme tabanlı modeller kullanarak beyin MR görüntülerinde tümör tespiti başarıyla yapılmıştır. Hibrit modellerin uygulanması, sınıflandırma doğruluğunu ölçüde artırarak daha yüksek performans elde edilmesini sağlamıştır. / In this study, tumor detection in brain MRI images was successfully performed using deep learning-based models. The application of hybrid models significantly improved classification accuracy, leading to higher performance.



## Hibrit Aktarım Öğrenme Tekniklerini Kullanarak Beyin Tümörü Sınıflandırmasında Yeni Sonuçlar

Doğuukan KALENDER<sup>1</sup> , Atahan ÖZTÜRK<sup>1</sup> , Ömer BİLGİN<sup>1</sup> , Durmuş Özkan ŞAHİN<sup>1\*</sup>

<sup>1</sup>Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Samsun, Türkiye

### Makale Bilgisi

Research article  
Received: 14/06/2024  
Revision: 26/10/2024  
Accepted: 04/12/2024

### Anahtar Kelimeler

Derin öğrenme  
Beyin tümörü tespiti  
Aktarım öğrenmesi  
Görüntü işleme  
Tibbi görüntü  
Tibbi görüntü sınıflandırma

### Öz

Bu çalışmada derin öğrenme modelleri kullanılarak beyin MR görüntüleri işlenmiştir. Kullanılan veri seti tümör bulunan ve bulunmayan görüntülerden oluşmaktadır. Bu görüntüler bazı ön-isleme aşamalarından geçerek modellerin eğitimi için uygun hale getirilmektedir. Çalışmada kullanılan derin öğrenme modelleri aktarım öğrenmesine dayalı modellerden oluşmaktadır. Bunlar MobileNet, VGG19, DenseNet169, AlexNet, ResNet101 ve InceptionV3 modelleridir. Bu modeller önceden eğitilmiş yapıda bulunmaktadır. Bu nedenle derin öğrenme modellerinin daha iyi genelleme yaparak doğru tahminlerde bulunmasını sağlarlar. Modellerin performansını artırmak için veri artırma, erken durduma, öğrenme oranı zamanlayıcısı, katman dondurma ve özel katmanların eklenmesi gibi yöntemler kullanılmıştır. Yapılan deneylerde en yüksek başarım doğruluk metriğine göre %98.63 ile MobileNet modelinden elde edilmektedir. Daha sonra deneylerden elde edilen sonuçlara göre en başarılı üç modelin ikili kombinasyonları alınarak hibrit modeller oluşturulmuştur. Önerilen bu hibrit modellerin kullanılması ile elde edilen en yüksek başarım doğruluk metriğine göre %99.21'dir. Bu sonuç VGG19 ve DenseNet169 modellerinin birleştirilmesiyle elde edilmiştir. Tüm hibrit modellerden elde edilen sonuçlar göz önünde bulundurulduğunda sınıflandırma başarısında %2'den fazla iyileştirme sağlanmıştır.

## New Results in Brain Tumor Classification Using Hybrid Transfer Learning Techniques

### Article Info

Araştırma makalesi  
Başvuru: 14/06/2024  
Düzelte: 26/10/2024  
Kabul: 04/12/2024

### Keywords

Deep learning  
Brain tumor detection  
Transfer learning  
Image Processing  
Medical image  
Medical image classification

### Abstract

In this study, brain MRI images were processed using deep learning models. The data set used consists of images with and without tumor. These images are made suitable for training models by going through some pre-processing stages. The deep learning models used in the study consist of models based on transfer learning. These are MobileNet, VGG19, DenseNet169, AlexNet, ResNet101 and InceptionV3 models. These models are pre-trained. Therefore, they enable deep learning models to generalize better and make accurate predictions. Methods such as data augmentation, early stopping, learning rate timer, layer freezing and adding special layers have been used to increase the performance of the models. In the experiments, the highest performance is obtained from the MobileNet model with 98.63% according to the accuracy metric. Then, according to the results obtained from the experiments, hybrid models were created by taking binary combinations of the three most successful models. The highest performance achieved by using these proposed hybrid models is 99.21% according to the accuracy metric. This result was obtained by combining VGG19 and DenseNet169 models. Considering the results obtained from all hybrid models, more than 2% improvement in classification performance was achieved.

## 1. GİRİŞ (INTRODUCTION)

Dünya Sağlık Örgütü'nün son verilerine göre beyin tümörleri dünya üzerinde ölüme sebebiyet veren ve en sık rastlanan kanser türlerinden biridir [1]. Bu bağlamda beyin tümörlerinde erken teşhis birçok hastayı kurtarabilir ve gerekli tedavinin zamanında yapılmasını sağlayabilir. Medikal alanda veri hacminde gözle görülür bir artış vardır ve

geleneksel modeller bununla verimli bir şekilde başa çıkamamaktadır. Son zamanlarda medikal görüntüleri kullanan makine öğrenimi analizi, büyük veri tekniklerinde önemli bir yere sahiptir.

Ulusal Beyin Tümörü Vakfı verisine göre her geçen yıl beyin tümörü teşhisi koyulan hastaların sayısı giderek artmaktadır [2, 3, 4]. Bundan dolayı geleneksel yöntemlerin çok zaman alması teşhis

koyulan hastaların tedavisine negatif yönde etki etmektedir. Bunun için alternatif bir yol olarak derin öğrenme kullanan otomatik karar destek sistemleri, alanında uzman kişiler tarafından teşhis yapılmasına ve tedavi sürecinin hızlandırılmasına katkı sağlar [5]. Bu çalışmada ise birçok sınıflandırma problemine başarılı bir şekilde uygulanan aktarım öğrenme tekniklerinin beyin tümörü sınıflandırma probleminde kullanılması amaçlanmaktadır. Ayrıca bu aktarım öğrenme teknikleri birleştirilerek hibrit modeller oluşturulmuştur. Önerilen bu hibrit modeller kullanılarak sınıflandırma başarısında iyileştirme sağlanmaktadır.

### 1.1. Literatür İncelemesi (Literature Review)

Shivam vd. yapmış oldukları beyin tümörü tespit ve sınıflandırma çalışmasında MRG, Bilgisayarlı Tomografi (BT), Pozitron Emisyon Tomografi taraması (PET SCAN) gibi görüntü tekniklerini kullanarak bu görüntülerin bir kısım incelemeden geçirmişlerdir. Bu aşamalar sırasıyla ön-isleme, katmanlama, eşikleme, özellik çıkarımı ve sınıflandırmadır. Bu aşamalardan geçen ve destek vektör makinesi (SVM) algoritmasına giren görüntüler alanında uzman kişiler tarafından görüntülenebilen bir görüntüye dönüştürülmüştür. Yaptıkları çalışma sonucunda %92 kesinlik değeri elde etmişlerdir [6].

Syed Muhammad vd. ise kullandıkları BRATS 2015 veri kümesiyle beraber görüntü işleme algoritmaları kullanmışlardır. Araştırmacılar MR görüntülerini alarak bu görüntülerden beyindeki tümörün şeklini, lokasyonunu ve dokusunu tespit etmeyi amaçlamışlardır. Çalışmalarında elle yapılan katmanlama işleminin çok zaman almasından ötürü bunu en hızlı şekilde halletmek istemeleridir. Yapılan araştırma yüksek seviyeli ve düşük seviyeli glial tümörler üzerinde olup tasarladıkları algoritma ile bu konuya bir çözüm getirmeyi amaçlamışlardır. Geliştirdikleri algoritma herhangi bir etiketli eğitim veri kümesine ihtiyaç duymamaktadır. Çalışmada tümörlü görüntülerin segmentasyonu için kullanılan algoritma, maksimum arka bekleni maksimizasyonu (MAP-EM) ve K-ortalamalar (K-Means) kümeleme algoritmasıdır. Çalışma sonucunda 0.92 DICE skor değerini elde etmişlerdir [7].

Aryan Sagar beyin tümörü görüntülemenin zorluklarından bahsetmiş olup bunlar hakkında çözüm önerileri sunmuştur. Görüntülemedeki zorlukların, tümörün farklı şekillerde ve dokularda olmasından kaynaklanabileceği söylemiştir. Tümör ve tümör olmayan görüntülerin makinelerde

okunmasında yoğunluğun etkili olduğunu söylemekle beraber bunun için histogram eşitleme ve açma gibi farklı ön-isleme tekniklerine projesinde yer vermiştir. Kullandığı veri kümesi farklı tümör şekilleri, boyutları, dokuları ve konumlarını kapsamaktadır. Sınıflandırma için ise evrişimsel sinir ağları (CNN) modeli kullanılmış olup buna dair başarı oranları makalesinde yer almıştır. Yaptığı çalışmada 20 devir kullanılmış olup eğitim, test ve doğrulama için ayrı F1 skorları hesaplanmıştır. Bunlar sırasıyla %98.65, %94.74 ve %99.59 değerleridir [8].

Antor Mahamudul vd. beyin tümörlerinin tespiti ve tedavisinin alanında uzman kişilerin tecrübesine bağlı olduğunu söylemişlerdir ve geliştirdikleri modelin bu konuda yardımcı olduğunu vurgulamışlardır. Yaptıkları modelde MR görüntülerinin doğru şekilde analiz edilmesi için evrişimli sinir ağları kullanılmışlardır. Bu yaptıkları uygulamada ellerine geçen görüntünün koyu kenarlarını bulup çıkaran görüntü ön işleme ve veri arttırma tekniklerinin olduğunu belirtmişlerdir. Bu işlemlerden sonra ise görüntünün uygun bir ölçük bulunarak normalize edildiğini söylemişlerdir. Çalışmalarında ADAM optimizasyonunu kullanmışlardır. Son olarak Kaggle'dan alınan veri kümesi üzerinde deneyler gerçekleştirilmiştir. Kullanılan veri kümesi üzerinde 400 tane görüntü bulunmaktadır. Bunlardan 230 tanesi tümörlü görüntünden oluşmaktadır. Geri kalan 170 görüntü ise tümör içermemektedir. Deney sonuçlarını F1 skoru ile hesaplamışlardır. Yaptıkları çalışmada test ve doğrulama için 0.89 ve 0.91 F1 skorlarını elde etmişlerdir [9].

Mehrdad vd. yaptıkları çalışmada gliomaların erken tanısında ve tedavisinde bu tümöre sahip olan kişilerin hayat kalitesinin arttığını öne sürümüştür. Derin evrişimli sinir ağları beyin tümörü sınıflandırmasında iyi bir performans vermesine karşın gliomaların değişen yoğunluk ve görünümlerinde bu yöntemin zorlu bir durum olduğunu belirtmişlerdir. Yaptıkları çalışmada iki boyutlu ve UNet tabanlı bir çalışma yapılmıştır. Deneylerini üç boyutlu yapmadıklarının sebebi şu şekilde açıklanmaktadır: üç boyutlu görüntülerde bağlamsal bilgiler kullanılmaktadır. Bu bilgilerde otomatik olarak daha fazla parametre ve hesap karmaşaklısına yol açar. Bu konuları daha basit bir şekilde çözmek için araştırmacılar bu yöntemi kullanan bir model geliştirdiklerini belirtmişler. Tasarlanan bu modelde başlıca iki teknik kullandıklarını söylemişlerdir. İlk teknik düşük ve yüksek seviye özelliklerin birleşmesinde kullanılan bir dikkat sistemidir. İkinci teknik ise çoklu görünüm füzyonudur. Bu teknik iki boyutlu

görüntülerin üç boyutlu görüntülerdeki bağlamsal bilgilerini kullanılmayı sağlamaktadır. Çalışma sonuçlarında ise 2017 ve 2018'in en iyi tekniklerinden daha iyi bir sonuç elde ettiklerini söylemektedir. Yaptıkları çalışmada ET, WT ve TC alt bölgelerinin DICE skorları hesaplanmıştır. Bunlar sırasıyla 0.813, 0.895 ve 0.823 değerleridir [10].

Sravanthi vd. yaptıkları çalışmada doktorlara beyin tümörlerinin erken tespiti konusunda yardımcı olmayı amaçlamışlardır. Çalışmalarında MR görüntülerinin çeşitli faktörlere bağlı olarak bozunuma uğrayabileceklerini söylemişlerdir. Bu faktörlerin ise gürültü ve diğer çevresel bozucular olduğunu belirtmişlerdir. Yaptıkları çalışmada diğer çalışmalardan farklı olarak görüntüyü gri tonlamaya dönüştürmüştürlerdir. Aynı zamanda görüntüyü diğer faktörlerden arındırmak için bazı filtreler uygulamışlardır. Yaptıkları işlemler görüntüyü bir ön-isleme sürecinden geçirerek modelin performansına katkı sağlamıştır. Bu işlemlerden geçen görüntünün kenarları çok net bir şekilde belli olmayabilir bu sebepten ötürü görüntü bölümleme kullandıklarına ayrıca degenmişlerdir. Son olarak önerilen modeli MATLAB ortamında tasarlayıp uygulamışlardır. Önerilen modelin altyapısı görüntü işleme ve SVM'dir. Yaptıkları çalışmada doğruluk değerini hesaplayarak bu değeri %97 olarak hesap etmişlerdir [11].

Marium vd. yaptıkları çalışmada beyin tümörlerinin beyin işlev bozukluklarını gibi bir takım sorunlara yol açabileceğine degenmişlerdir. Beyin tümörlerinin tespiti için günümüzde güncel olarak MRG ve BT taramaları kullanılmaktadır. Son yıllarda bu taramalardan elde edilen görüntüler üzerinde derin öğrenme algoritmaları, görüntü işleme ve bilgisayar görüşü gibi birçok teknik uygulanmıştır. Araştırmacılar çalışmalarında MRG taramalarının, görüntü işleme ve derin öğrenme tekniklerinin karşılaşmasını ele almışlardır. Kendi sistemlerini dört basit adımda açıklamaktadırlar. Bu adımlar şöyledir: ilk olarak kaliteyi ayarlamak için bir ön-isleme tekniği kullanılmıştır. İkinci olarak görüntü iyileştirme yöntemlerini kullanarak görüntüyü geliştirmişlerdir. Üçüncü olarak kenarları daha belirgin hale getirmek için kenar tespit yöntemi kullanılmıştır. Dördüncü ve son adımda ise morfolojik operatörler ile görüntü katmanlamayı kullanarak tümörün lokasyonu tespit edilmiştir. Bu aşamalar bittikten sonra derin öğrenme teknikleri kullanılarak sonuçların karşılaştırılması yapılmaktadır. Yaptıkları çalışmanın amacını ise kısaca şöyle açıklamışlardır. Derin öğrenme algoritmaları daha iyi sonuçlar üretebileceği ve

beyin tümörünün tespitinde MR görüntülerinde çoklu sınıflandırmaları gerçekleştirebileceğini belirtmişlerdir [12].

Shirin vd. yaptıkları çalışmada beyin tümörünün erken teşhis edilmesine dikkat çekmişlerdir. Beyin tümörlerinin şekilleri, tümörün beyin içindeki sınırları, konsistansı gibi sebepler bu işi manuel olarak yapmanın zorluklarıdır. Kendileri yaptıkları modelde özellik tespiti için bir adet kodlayıcı, katmanlama için ise bir kod çözümü ve sınıflandırma için bir adet çok katmanlı algılayıcı kullanmışlardır. Kullandıkları çok katmanlı algılayıcıyı meningomaları, gliomaları ve balgamsı adenomalar için kullanmışlardır. Çalışmalarındaki çok özellikli derin öğrenme modelinde büyük bir iyileştirme yapıldığından bahsetmişlerdir. Bunu da her tahmin için %97 doğruluk oranı ile yakalamışlardır [13].

Akila ve Batri yaptıkları çalışmada MR görüntülerinden faydalananmışlardır. Beyin tümörlerinin erken tespitinin önemine dikkat çekmiş olup erken önlem alınmadığı zaman sonuçlarının ölümcül olacağına belirtmişlerdir. Çalışmalarında MR görüntülerini derin öğrenme algoritmalarında kullanarak beyin tümörü tespiti konusunda çalışmışlardır. Çalışmalarını üç alt başlıkta incelemiştir. Bunlar ön-isleme, katmanlama ve sınıflandırma şeklidendir. Ön-isleme aşamasında veri artırımı yapmışlardır. Sınıflandırma kısmında beyinde tümör olup olmadığı konusuna degenmişlerdir. Katmanlama kısmında ise evrişimli sinir ağlarının sınıflandırma mimarisini kullanıp beyin görüntülerini sınıflandırmışlardır. Veri kümesi olarak BRATS 2015 verilerini kullanmışlardır. Bu veriler toplamda 256 tanedir. Bunlardan 152 tanesi normal tümör geri kalan 104 tanesi ise anormal tümör olarak etiketlidir. Son olarak evrişimli sinir ağları mimarisi kullanmadan önce elde ettikleri F1-skor değeri %95.6 iken evrişimli sinir ağları mimarisi kullanıldıktan sonra bu değer %98.1'e çıkmıştır [14].

Eker ve Duru çalışmalarında hastalık teşhisi için uzmanların yoğunluklarını minimum seviyeye düşürmeye katkıda bulunmak amacıyla makine öğrenmesi algoritmalarından faydalananmışlardır. Araştırmacılar çalışmalarında derin öğrenme yöntemlerinin medikal görüntü işleme alanındaki uygulamalarını incelemiştir. Çalışmalarında segmentasyon ve sınıflandırma gibi konulara dikkat çekmişlerdir. Bu incelemelerin yanında ayrıca U-net derin öğrenme mimarisi ile beyin tümörü segmentasyonu gerçekleştirilmiştir. Veri seti olarak BraTS 2020 kullanılmışlardır. Bu veriler üzerinde gerekli gerçeklemeleri yapıp sonuç olarak %86

DICE benzerlik oranı ve %80 hassasiyet değeri elde etmişlerdir [15].

Nadim Mahmud vd. yaptıkları çalışmada beyin tümörünün erken teşhisine dikkat çekmişlerdir. Bu amaçla yaptıkları çalışmayı iki kısma ayırmış olup ilk kısımda beyin tümörü tespiti ikinci kısmında ise derin öğrenmeyi kullanarak MR görüntülerini sınıflandırmışlardır. Kullandıkları YOLO (You Only Look Once) ve derin öğrenme kütüphanesi olan FastAi mimarisinden faydalananmışlardır. Çalışmalarında kullandıkları veri kümesi BRATS 2018 verileri olmakla beraber bu verilerin içinde 1992 adet beyin MRG taraması bulunmaktadır. Çalışmada toplam 1992 taramış MR görüntüsü kullanılmıştır. Modellerini eğitmek amacıyla 1494 (toplam verilerinin %75'i) görüntü kullanılmış olup geri kalan 498 (toplam verilerin %25'i) görüntü ise modeli test etmek için kullanılmıştır. Son olarak kullandıkları FastAi ve YOLO modellerini karşılaştırmak amacıyla yaptıkları deneylerde FastAi için %95.78 YOLO için ise %85.95 doğruluk oranına ulaşmıştır. Buna ek olarak FastAi için %96.17 F1-skor değerini YOLO için ise %88.30 F1-skor değerini elde etmişlerdir [16].

Jemimma ve Jacob farklı bir yaklaşım kullanarak çalışmalarını Watershed (Su-bölümleme) algoritmasıyla yapmışlardır. Yaptıkları çalışma temelinde beyin tümörü tespiti ve sınıflandırması üzerindedir. Çalışmalarının temeli Watershed Dynamic Angle Projection - Convolution Neural Network (WDAPP-CNN) üzerine kurmuşlardır. Kendileri Watershed algoritmasının tümörlü bölgeyi yüksek doğruluk oranı ile segmente ettiğini bu yüzden Watershed kullandıklarını söylemiştir. Segmentasyonda iki temel yaklaşım vardır. Bunlar sınır yaklaşımı ve bölgesel yaklaşımındır. Watershed ise bu iki yaklaşımın kombinasyonu şeklinde işler. Çalışmalarında Watershed tercih etmelerinin sebebinin bu olduğunu söylemişlerdir. Watershed algoritması ile segmentasyon kısmını kullanıp diğer kısımda ise Dynamic Angle Projection Pattern (Dinamik Açı Projeksiyon Deseni) yapısını kullanmışlardır. Son kısımda ise evrişimli sinir ağlarını kullanarak sınıflandırma aşamsına geçilmiştir. Kullandıkları veriler BRATS verileri olmakla beraber 30 adet hastanın görüntüsü olduğunu söylemişlerdir. Çalışmalarının sonunda başka çalışma metodlardı ile kendi metodlarını kıyaslamışlardır. Kullanılan metodlar arasında DWT-SGLDM, LRACM, MAP-MRF, LaV gibi teknikler bulunup önerilen WSA-DAPP ile %93.5 DICE Score ve %94.2 gibi bir hassaslık değeri elde etmişlerdir. Kendilerine en yakın metot LaV metodudur. LaV

metodunda ise %91.27 DICE skor ve %92.08 hassaslık değeri elde edilmiştir [17].

Periasamy vd. yaptıkları çalışmada VGG-19 modeli ile RESNET-50 modelinin karşılaştırmasını yapmışlardır. Çalışmalarının başında birinci derece beyin tümörüne rastlanan hastaların yaşama oranının %75.2 olduğunu belirtmişlerdir. Bu bağlamda beyin tümörünün erken teşhisinin insan hayatında kritik bir rol oynadığını söylemişlerdir. Geleneksel prosedürlerin hem yavaşı olduğunu hem de insan hatasına açık olduğunu vurgulamışlardır. Bu tür zorlukların minimum düzeye indirilmesinde bilgisayar destekli teşhis yöntemlerinin kaçınılmaz olduğunu da ayrıca değinmişlerdir. Çalışmalarında VGG19 ve ResNet50 modelini aynı veri kümeleri üzerinde kullanarak iki modelin karşılaştırmalarını yapmışlardır. Modellerin temelinde görüntü kırpmaya, tekrar boyutlandırma, veri artırımı, model yapımı ve çıktıların alınıp sınıflandırılması yer almaktadır. Kullandıkları veri kümesini Kaggle'dan almışlardır. Bu veri kümesinde 253 MR görüntüsü olup bunların 98'i beyin tümörü içermezken 155 tanesi ise tümörlü MR görüntüsüdür. Çalışmanın sonunda elde edilen sonuçlar şöyledir: VGG19 modelinin eğitim verileri için alınan kesinlik, hatırlama, F1-skor ve doğruluk değerleri %94.28, %100, %97.05 ve %96.93 test verileri için değerler ise kesinlik, hatırlama, F1-skor ve doğruluk olmak üzere %96.0, %96.0, %96.0 ve %97.05'tir. ResNet-50'nin eğitim verilerinden alınan değerler sırasıyla kesinlik, hatırlama, F1-skor ve doğruluk olmak üzere %97.05, %100, %98.50, %98.46 test verilerinde ise değerler %100, %96.0, %97.95 ve %97.91 şeklinde raporlanmaktadır [18].

Tapesh Kumar vd. evrişimli sinir ağlarını kullanarak beyin tümörü tespiti adına bir çalışma yapmışlardır. Beyinin içinde milyarlarca nöron olduğunu ve beyinin içinde oluşan bir tümörün insan vücuduna etkisinin büyük olabileceğiinden bahsetmişlerdir. Bu bağlamda erişime açık veri kümelerinin olduğu çeşitli veri kümelerini birleştirerek örnek sayılarının artırılması hedeflenmiştir. Bu veri kümelerinin içinde farklı renkte görüntüler olduğundan bu görüntüler griye çevirmek için GaussianBlur filtresini kullandıklarını vurgulamışlardır. Kullanılan veri kümelerinden biri BR35H:Brain Tumor Detection 2020'dir. Bu veri kümesinde 1500 sağlıklı 1500 tümörlü görüntü olmak üzere 3000 görüntü bulunmaktadır. Diğer kullanılan veri kümesi ise Github üzerinden sağlanmıştır. Bu veri kümesinde ise 1019 sağlıklı 1308 adet ise tümörlü görüntü vardır. Bu bağlamda toplam 5327 beyin görüntüsü üzerinde modelleri eğitim ve test için kullanılmışlardır. Toplam verinin %80'i kadarını

modellerini eğitmek için %20'lik kısmını ise test için ayrılmıştır. Bunlara ek olarak çalışmalarında ROC Eğrisi, Karışıklık Matrisi ve Doğruluk Eğrisi gibi farklı veri görselleştirme teknikleri ile modelin başarımları değerlendirilmiştir. Modellerindeki kullandıkları katmanlar ise Dense, Max Pooling, Batch normalizasyon ve evrişim katmanlarıdır. Kullandıkları modelin eğitim aşamasındaki doğruluğu %99.59 doğrulama aşamasındaki doğruluğu %98.36 ve test aşamasındaki doğruluğu %99.15'dir [19].

Meena ve Shantha'nın yaptıkları çalışmanın amacı seçikleri modelleri kullanarak beyin tümörü tespit etmektir. Analiz kısmına geldiklerinde ise temel olarak kullandıkları üç aktarım öğrenmesi kullanan modelden bahsetmişlerdir. Bunlar sırasıyla VGG16, ResNet ve Inception modelleridir. Modellerinde evrişimli sinir ağlarını kullanmış olup ileri besleme ve geri besleme kullandıklarını belirtmişlerdir. Bu şekilde modellerinin ağırlık değerlerini bulmuşlardır. Ellerindeki bu modelleri ImageNet veri kümesi üzerinden alıp eğittiğini belirtmişlerdir. Eğitim için kullanılan veri kümesi 102 adet tümörsüz görüntü ve 118 adet tümörlü görüntünden oluşmaktadır. Veri kümesinin test aşamasında ise 40 tümörsüz görüntü ve 44 adet tümörlü görüntü bulunmaktadır. Ellerindeki bu görüntülerin boyutları ise  $256 \times 256$  şeklindedir. En optimum veri kümesini yakalamayabilmek için veri artırımı yöntemini kullanmışlardır. Bu yöntemler farklı dallara ayrılmış döndürme, çarpıklık, çevirme ve kesme şeklinde dir. Çalışmada döndürme kullanılmış olup bu döndürmeyi 10 ve 20 derece açılarında yapmışlardır. Sonuçlara bakıldığına veri artırımı tekniği kullandıklarında aldıkları doğruluk değerleri hepsinde %100 iken kullanmadıklarında ise sırasıyla %92.9, %97.6 ve %97.6 değerlerdir [20].

Nidaan vd. çalışmalarında beyin tümörü sınıflandırmasında Alexnet mimarisini kullanmışlardır. Beyin tümörü tespitinde erken tespitin ne kadar kritik olduğuna ayrıca degenmişlerdir. Veri kümeleri 3264 adet halka açık görüntü olduğunu ve bu görüntüleri Kaggle üzerinden aldıklarını belirtmişlerdir. Veri kümelerini 2870 adedini eğitim 394 adedini ise modelin testi için kullanmışlardır. Ellerindeki verilere ön-islem uygulamışlardır. İlk aşamada 512 piksellik görüntüleri yeniden boyutlandıracak 224 piksele çevirmişlerdir. Ardından ölçeklendirme yaparak ölçegini  $1/255$ 'e getirmiştir. Son olarak ise Grayscale teknğini kullanarak ellerdeki görselleri gri renge dönüştürmüştür. Kullandıkları bu modellerde optimize edici olarak ADAM, SGD, NADAM, RMSPROP ve ADAMAX

kullandıklarını belirtmişlerdir. Her kullandıkları optimize edici için doğruluk, kesinlik, hatırlama ve F1-skor değerlerini hesaplamışlardır. Bu değerlerin modellerden çıktıısı sonucunda hepsinde en yüksek değerleri ADAMAX optimizasyon fonksiyonu verirken en düşük değerler ise NADAM optimizasyon fonksiyonundan elde edilmiştir. Aynı zamanda çalışmalarında modellerin öğrenme katsayısını değiştirmiştir. Sırasıyla 0.1, 0.01, 0.001, 0.0001 değerlerini kullanmışlardır. Bunların arasında en yüksek sınıflandırma başarımı öğrenme katsayı 0.001 değeri olduğunda elde edilmiştir [21].

Manoj Kumar vd. yaptıkları çalışmada YOLOv5x modelini kullanarak beyin tümörü tespiti ve sınıflandırması yapmışlardır. Bu yola çıkış amacı olarak beyin tümörü tespitinde erken teşhis ve sınıflandırmanın medikal alanda çok büyük rol oynadığını ve tespit edilen tümöre göre teşhisin konulup buna göre yol haritasının çizilmesinin çok önemli olduğunu söylemektedirler. Geleneksel yöntemlerin çok zaman kaybettirdiğini ve efor istedigini de ayrıca vurgulamışlardır. Çalışmalarında YOLOv5x modeli ile bu zaman ve eforu en düşük düzeye indirip beyin tümörü tespitini yapmayı planlamışlardır. Kullandıkları veri setini Brats ve Roboflow'dan aldıklarını ayrıca yaklaşık 5000 adet görüntü üzerinde çalışıklarını söylemişlerdir. Bu verileri farklı boyutlarda ve renklerde olmasından ötürü ikinci aşama olarak verilerini ön-isleme sürecine sokarak modelin girdisine uygun hale getirmiştir. Kullandıkları YOLOv5x modelinin ağırlıklarının önceden eğitilip kendi verilerine en uygun şekilde olduğunu belirtmişlerdir. Performans ölçütleri olarak ise hatırlama, ortalama hassasiyet (mAP), doğruluk ve F1-skor ölçütlerini kullanmışlardır. Çalışmalarının son kısmında ise aldıkları sonuçlar tartışılmıştır. Elde edilen performans ölçüt değerleri şu şekildedir: ortalama hassasiyet değeri: %89.3, hatırlama değeri: %93, F1-skor değeri: %87 ve kesinlik değeri: %90.8. Araştırmacılar YOLOv5x modelinin gerekli girdi koşulları uygulandığında güvenilir ve iyi çalıştığını vurgulamaktadırlar [22].

Çınarer ve Emiroğlu çalışmalarında beyin tümörü tespitinde makine öğrenmesi algoritmalarını kullanmaktadır. Kendileri, beyin tümörlerinin kansere bağlı ölüm sebeplerinden en önemli olduğunu vurgulamışlardır. Bu yolda erken teşhisin anahtar bir rol oynadığını söylemişlerdir. Makine öğrenmesi ve sınıflandırma algoritmasını kullanmanın en temel amacı daha doğru kararları yüksek doğruluk oranı ile vermesi olarak belirtmişlerdir. Çalışmalarında sınıflandırma metodlarının performansı üzerinde

yoğunlaşmışlardır. Bu alanda da fazlaca bilinen ve kendilerinin de kullandığı algoritmalar şunlardır: K En Yakın Komşu (KNN), Rastgele Orman, Destek Vektör Makinesi ve Doğrusal Ayırma Algoritması. Çalışmalarında REMBRANDT veri seti kullanılmıştır. Bu veri kümelerinde 99 hastanın MR görüntüleri bulunmaktadır. Her hasta için ise 30'a yakın MR görüntüsü olduğu belirtilmiştir. Her bir algoritma için farklı sınıflandırma sonuçları bulunmuştur. Doğruluk metriğine göre KNN algoritması 0,87 değerini, SVM algoritması 0,90 değerini, LDA algoritması 0,83 değerini ve RF algoritması 0,83 değerini vermiştir. Bunların yanında kullandıkları diğer performans ölçütleri ise kesinlik, hassasiyet ve F1-skor metrikleridir. Kesinlik ölçüyü için SVM algoritması diğerlerine 3-4 puanlık bir fark atmış olup %90 değerine ulaşmıştır. Hassasiyet için de benzer sonuçlar elde edilmiştir. SVM algoritması bu ölçütte de %90 değerini yakalamıştır. Son olarak F1-skor ölçütünü iki alanda ele almışlardır. Eğitim sonuçlarına göre KNN: %83, SVM: %83, LDA: %90 ve RF: %83 şeklindedir. Test sonuçları ise KNN: %90, SVM: %90, LDA: %83 ve RF: %90 şeklindedir. Toplam dört algoritma arasından maksimum doğruluk değerini yakalayan algoritma SVM algoritmasıdır. Sınıflandırma çalışmalarında SVM algoritması en yüksek hassasiyet değerini ve doğruluk değerini yakalamıştır. Bu bağlamda diğer algoritmalarдан çok daha etkin bir algoritma olduğunu vurgulamışlardır [23].

Aslan çalışmasında beyin tümörü tespiti için MobilNetV2 modelini kullanarak beyin tümörü tespiti yapmayı amaçlamıştır. MobilNetV2 modelinde farklı olarak KNN algoritmasını kullanmıştır. Aslan çalışmasından elde ettiği sonuçları birçok araştırmada kullanılan model ve yöntem ile kıyaslamıştır. Bu yöntemlere bölütleme algoritmaları, Markov rastgele alan, Ayrik Dalgacık Dönüşümü, CapsNet, Destek Vektör Makinası, Çok Katmanlı Algılayıcılar, Lojistik Regresyon, Alexnet, VGG örnek olarak verilebilir. Çalışmanın temelinde kullanılan üç ana bölüm vardır. Bunlar veri artırma, derin öznitelik çıkarımı ve sınıflandırma adımlarıdır. İlk aşamada veri kümelerinde bulunan 253 MR görüntüsü veri artırma ile 1265 örnek görüntüye çıkartılmıştır. Daha sonra bu görüntülerini MobileNetV2 modelinin girişine uygun olarak 224x224x3 şeklinde boyutlandırılmıştır. Öznitelik çıkarımı kısmında ise model çalıştırılıp "Logits" tam bağlı katmanından 1000 derin öznitelik bulunmuştur. Son aşamada KNN algoritması kullanılmıştır ve 1000 öznitelik KNN' girdi olarak verilmiştir. 253 MR görüntüsünden 155 adedi tümörlü iken 98 adedi ise tümörsüz görüntüdür. Çalışmada doğruluk,

duyarlılık, özgüllük, keskinlik, F1-Skor ve Matthews Korelasyon Katsayı (MCC) metrikleri ile sınıflandırma başarımları değerlendirilmiştir. Bu ölçütlerle bağlı olarak orijinal ve çoğaltılmış veri setleri üzerinde karşılaştırmalar yapılmıştır. Orijinal veri seti üzerinde doğruluk metriğine göre KNN olmadan %86.56 başarım elde edilirken KNN ile birlikte %89.72 başarım elde edilmiştir. Duyarlılık metriğine göre KNN algoritması olmadan %86.73 KNN algoritması ile birlikte %88.78 başarım elde edilmiştir. Diğer metriklerden elde edilen sonuçlar incelendiğinde de KNN modeli kullanmanın sınıflandırma başarısına olumlu yönde etki ettiğini gözlemlenmektedir. Verilerin çoğaltılmamasından sonraki durumda ise bütün değerlerde bir artış olduğunu ayrıca belirtilmektedir. Sonuç olarak araştırmacıının yaptığı bu çalışmada kullanılan veri artırma ve KNN algoritmasının modelin performans değerlerinde iyileştirme olduğunu göstermektedir [24].

## 1.2. Motivasyon ve Katkı (Motivation and Contribution)

Geleneksel yöntemler beyin tümörü tespitinde zaman ve verimlilik kaybına neden olmaktadır. Onerilen beyin tümörü tespit sistemi ile hastalık teşhisinde oluşan zaman ve verimlilik kaybının önüne geçilmesi hedeflenmektedir. Ayrıca başarılı derin öğrenme modelleri sayesinde beyin tümörlerinin doğru ve hızlı bir şekilde tespit edilmesi ana motivasyonumuzdur. Bu doğrultuda aktarım öğrenmesi modellerini kullanarak beyin tümörü tespiti sisteminin başarımı nasıl olur sorusuna cevap verilecektir. Çalışmanın ana katkıları şöyle özetlenebilir:

- MobileNet, VGG19, DenseNet169, AlexNet, ResNet101 ve InceptionV3 aktarım öğrenme modelleri dengeli bir veri kümeli üzerinde çalıştırılarak başarımları değerlendirilmiştir.
- MobileNet F1-Skor metriğine göre %98.67 başarım ile en başarılı model olmaktadır. VGG19 ve DenseNet169 ise MobileNet'den sonra en başarılı modellerdir. Bu modellerin başarımları ise sırasıyla %97.89 ve %97.59 olmaktadır.
- Kütüphanenin sağladığı layers.concatenate modülü kullanılarak en başarılı 3 model olan ağlar ikili bir şekilde birleştirilerek hibrit ağ modelleri oluşturulmuştur. Bu ağ modellerinden en başarılı olanı VGG19-DenseNet169 birleşimidir. Bu hibrit model F1-Skor metriğine göre %99.22 başarım vererek sınıflandırma performansı iyileştirilmiştir.
- Aktarım öğrenmeleri tek başına kullanıldığından elde edilen en düşük başarım F1-Skor metriğine

göre %96.44 olurken hibrit modellerden elde edilen en düşük başarım oranı F1-Skor metriğine göre %98.67 olmaktadır. Bu durumda %2'den fazla sınıflandırma başarımda iyileştirme sağlanmaktadır. Hibrit modellerden elde edilen en yüksek başarım göz önünde bulundurulduğunda ise %3'e yakın sınıflandırma başarımda iyileştirme yapılmıştır.

### 1.3. Organizasyon (Organization)

Çalışmanın geri kalan kısımları şu şekildedir: Bölüm 2'de, çalışmanın altyapısının oluşturulmasında kullanılan programlama diline, kitaplara ve veri kümese degeinilecektir. Bölüm 3'te, derin öğrenme tabanlı beyin tümörü tespit sisteminin mimarisi ve bu mimariye ait detaylar verilecektir. Bölüm 4'te yöntemlerden elde edilen sonuçlar verilerek yorumlanacaktır. Bölüm 5'te ise genel değerlendirme yapılip gelecek çalışmalar hakkında bilgi verilecektir.

## 2. DENEYSEL AYARLAMALAR (EXPERIMENTAL SETTINGS)

Bu bölümde beyin tümörü tespit sisteminin altyapısında kullanılan bileşenler tanıtılacaktır. Bu bölüm 3 alt bölümde olmaktadır. İlk alt bölümde kullanılan programlama dili ve bu dile ait yararlanılan kitaplara degeinilecektir. İkinci alt bölümde ise çalışma kapsamında kullanılan veri kümlesi tanıtılacaktır. Son olarak üçüncü alt bölümde ise sınıflandırma başarıminın ölçülmesinde kullanılan metrikler yer verilecektir.

### 2.1. Kullanılan Programlama Dili ve Kitaplıklar (Programming Language and Libraries Used)

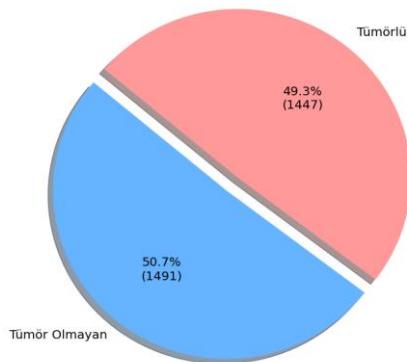
Yapılan çalışmanın gerçekleştirildiği ortam olan Google Colab genellikle makine öğrenimi, derin öğrenme ve veri analizi gibi hesaplama yoğunluklu alanlar için kullanılmaktadır. Kullanıcıların Python kodlarını bulut ortamında yazıp çalıştmalarına imkân sunan ücretsiz bir platformdur [25]. Genel amaçlı ve yüksek seviyeli bir programlama dili olan Python, Guido van Rossum tarafından 1991 yılında geliştirilmiştir. Nesne yönelimli, etkileşimli ve modüler özelliklere sahip olmasıyla birlikte okunabilir ve yazılabılır sözdizimine sahiptir [26].

Çalışmada kullanılan Python kütüphaneleri ise şunlardır:

- **Keras:** Keras kütüphanesi derin öğrenme modeli oluşturmak, eğitmek ve değerlendirmek için kullanılan bir kütüphanedir. Kullanımı kolay olan Keras, karmaşık derin öğrenme modellerini birkaç kısa kod bloğuyla oluşturmayı ve eğitmeyi mümkün hale getirir. Keras hızlı model geliştirme ve araştırma amacıyla geliştirilmiştir. Çeşitli katmanlar, optimizasyon yöntemleri, aktivasyon fonksiyonları gibi özellikler sunarak, kullanıcılar esnek ve özelleştirilebilir modeller geliştirebilecekleri bir fırsat sunar [27].
- **OpenCV:** Bu kütüphane bilgisayarlı görü ve görüntü işleme için çokça kullanılan bir kütüphanedir. Temelinde görüntü işleme, dönüşümler ve işlemler yapmak için kullanılır. Bu kütüphanenin yapabildiği başlıca işlemlerden bahsetmek gerekirse kullanılan görüntüye gri tonlama uygulama, gürültü temizleme ve görüntü kırpma gibi görüntü işlemek için belli fonksiyonları vardır [28].
- **PyTorch:** PyTorch, derin öğrenme uygulamalarında sıkça kullanılan Python dilinin bir kütüphanesidir. Temeli tensorlara dayanan Pytorch'un öne çıkan birkaç özelliği otomatik fark alma ve dinamik hesaplama grafiğidir. Bunlar model geliştiren yazılımcılar için oldukça elverişlidir. PyTorch birçok kullanıcı tarafından kullanılması sayesinde bu kütüphanede araştırma yapanlar derin öğrenme modelleri ve optimizasyon gibi stratejileri rahatlıkla kullanabilirler. Kütüphanenin bize sunduğu esneklik ve kolaylık çalışmada analiz ve işleme açısından gözle görülür bir kolaylık sağlamıştır [29].

### 2.2. Kullanılan Veri Kümesi (Dataset Used)

Çalışma kapsamında kullanılan veri seti Kaggle'dan alınmıştır [30]. Bu veri seti üzerinde 2938 tane beyin MR görüntüsü bulunmaktadır. Bunların 1491 tanesi tümör olmayan beyin görüntüsü ve 1447 tanesi de tümörlü beyin görüntüsüdür. Veri setindeki görüntülerin dağılım grafiği Şekil 1'de verilmiştir.



**Şekil 1.** Veri Kümesindeki Sınıf Dağılımları (Class Distributions in the Dataset)

Çalışmada kullanılan toplam veri setinin %70'i eğitim %30'u test için kullanılmıştır. Veriler karıştırılarak bölünmektedir. Tüm modellerde aynı bölümlemeyi yapmak için rastgele durum parametresi tüm modeller için "0" olarak seçilmiştir. Modellerin daha verimli eğitilmesi için veri setindeki görüntüler  $240 \times 240$  piksel formatından yeniden boyutlandırılarak  $128 \times 128$  piksel formatına getirilmiştir. Veri setinde bulunan rastgele seçilmiş tümörlü ve tümör olmayan MR görüntüleri Şekil 2'de gösterilmiştir.

### 2.3. Başarım Değerlendirme (Performance Evaluation)

Çalışmada dört farklı performans ölçüyü kullanılmıştır. Bunlar sırasıyla doğruluk (accuracy), kesinlik (precision), hatırlama (recall) ve F1-Skor ölçütleridir. Ölçütlerin matematiksel gösterimi Eşitlik 1, 2, 3 ve 4'te sırasıyla verilmiştir [31, 32]. Bu ölçütleri hesaplamak için modelin tahminlerinin

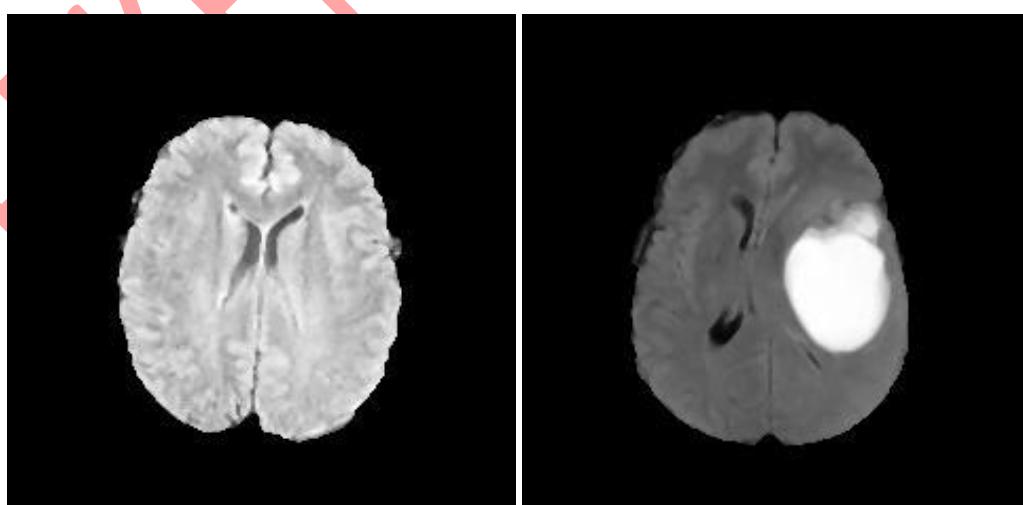
sonuçlarını içeren karmaşıklık matrisindeki değerler kullanılır. Bunlar sırasıyla doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP), yanlış negatif (FN) değerleridir. Verinin gerçek değeri pozitif ve modelin verdiği etiket de pozitif ise bu doğru pozitiftir. Verinin gerçek değeri pozitif ve modelin verdiği etiket negatif ise bu doğru negatiftir. Verinin gerçek değeri negatif ve modelin verdiği etiket pozitif ise bu yanlış pozitiftir. Verinin gerçek değeri negatif ve modelin verdiği etiket de negatif ise bu yanlış negatiftir.

$$\text{Doğruluk} = \left( \frac{TP+TN}{FP+FN+TP+TN} \right) \times 100 \quad (1)$$

$$\text{Kesinlik (Precision)} = \left( \frac{TP}{TP+FP} \right) \times 100 \quad (2)$$

$$\text{Hatırlama (Recall)} = \left( \frac{TP}{TP+FN} \right) \times 100 \quad (3)$$

$$\text{F1 Skor} = 2 \times \left( \frac{\text{Kesinlik} \times \text{Hatırlama}}{\text{Kesinlik} + \text{Hatırlama}} \right) \times 100 \quad (4)$$

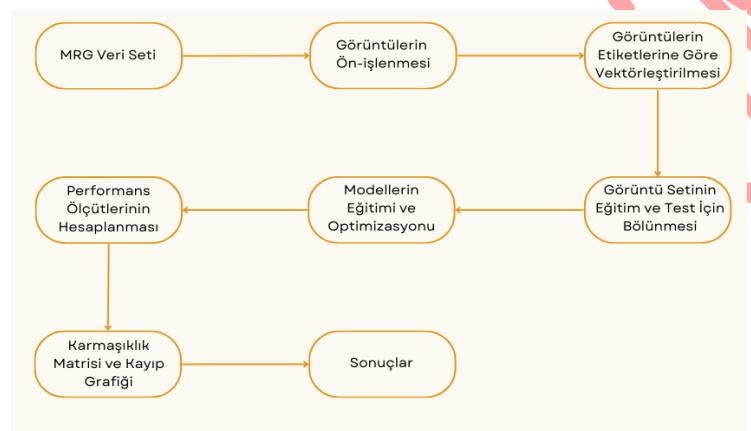


**Şekil 2.** Kullanılan Veri Setinden Rastgele Seçilmiş Beyin MR Görüntüleri (Randomly Selected Brain MRI Images from the Data Set Used)

### 3. YÖNTEM (METHODOLOGY)

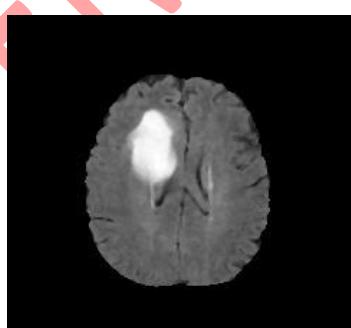
Yapılan çalışmanın genel işleyişi Şekil 3'te verilmiştir. İlk olarak tümör içeren ve tümör içermeyen MR görüntülerini bulunan veri seti kullanıma hazır hale getirilmelidir. Ardından bu görüntüler bir takım ön işlemlerden geçirilir. Bu ön işlemler gri tonlama, eşikleme (thresholding), kontur bulma, en büyük konturu seçme, sınırlayıcı kutu oluşturma ve son olarak görünütüyü kırpma adımlarından oluşmaktadır. Gri tonlama işleminde renkler kaldırılır ve gri tona çevirerek sadece parlaklık bilgileri bırakılır. Eşikleme işleminde ise

elde edilen görüntü cv2.threshold fonksiyonu kullanılarak ikili görüntüye çevrilir. Bu yöntemdeki asıl amaç belli bir değer belirleyip bu değerin üstünde kalan pikselleri beyaza(255), altında kalanları ise siyaha(0) çevirmektir. Bu işlem beyin yapısını arka plandan ayırtmaya yarar. Kontur bulma yönteminde ise cv2.findContours fonksiyonu kullanılarak, eşikleme yönteminden elde edilen ikili görüntülerde beyaz piksellerin sınırları belirlenir ve bu sınırların yapısı çıkarılır. En büyük konturu seçmek bu yöntemde çok önemlidir. Bunun sebebi ise tüm beyinin yapısını temsil etmesidir. Sınırlayıcı

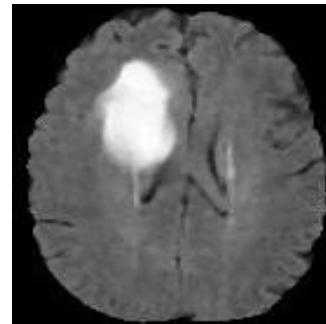


**Şekil 3.** Sistemin Genel Mimarisi (General Architecture of the System)

kutu oluşturulması bölümünde önceki aşamalarda seçilen konturun etrafına dikdörtgen bir kutu çizilir. Bu çizilen kutu konturu çevreleyen en küçük dikdörtgendir. Son aşama olan görüntü kırmada ise dilimleme yöntemi ile oluşturulan sınırlayıcı kutu kırılırlarak ilgili nesne ortaya çıkartılır. Böylece görüntü artık derin öğrenme modellerinin kullanımına hazır hale getirilmiş olacaktır. Şekil 4'te ve Şekil 5'te bu aşamaların görüntüye uygulanmadan önceki hali ve sonraki hali gösterilmiştir.



**Şekil 4.** Rastgele Seçilmiş Bir Beyin MR Görüntüsünün Ön-İşleme Aşamasından Öncesi (Before the Pre-Processing Stage of a Randomly Selected Brain MRI Image)



**Şekil 5.** Rastgele Seçilmiş Bir Beyin MR Görüntüsünün Ön-İşleme Aşamasından Sonrası (After the Pre-Processing Stage of a Randomly Selected Brain MRI Image)

Veri setinde bulunan görüntüler tümör bulunanlar için evet (yes) bulunmayanlar için ise hayır (no) şeklinde ikiye ayrılır. Veri ve etiketlerin doğru olup olmadığı kontrol edilir. OneHotEncoder işlemine tabi tutularak veriler sayısal bir formatla kategorilere ayrılır. Ardından her kategori ikili (0 ve 1) rakamları bulunduran bir vektöre dönürtülür. Veri setindeki veriler ve oluşturulan etiketler kullanılan fonksiyon ile belirli oranda karıştırılarak ayrılır. Fonksiyon dört çıktı üretir. Bunlar eğitim aşamasında kullanılacak veri özellikleri olan

"x\_train", test aşamasında kullanılacak veri özelliklerini olan "x\_test", eğitim aşamasında kullanılacak etiketler olan "y\_train" ve test aşamasında kullanılacak etiketler olan "y\_test" çıktılarıdır. Bu işlemin ardından kullanılan modelin "x\_train" ve "y\_train" ile eğitimi sağlanır. "x\_test" ve "y\_test" ile performansı değerlendirilir. Ardından veri özelliklerini içeren çıktılar normalize edilerek modelin performansı arttırılır bu sayede daha hızlı ve daha doğru bir öğrenim hedeflenmiş olur. Son olarak veri artırma (data augmentation) işlemi uygulanır. Bu işlem veri setindeki eğitim için kullanılan görüntüleri çeşitlendirerek farklı varyasyonları oluşturur. Bu sayede modelin eğitim sırasında genelleme yapma ve farklı şekildeki görüntüleri tanımaları sağlanır. Çalışmada kullanılan ImageDataGenerator sınıfı, görüntüler üzerinde dönüşümler uygulayarak veri artırımı yapar. Bunu yaparken bir takım parametreler kullanır. Bu parametreler ise sırasıyla şu şekildedir;

- rotation\_range: Bu parametre sıfır ile girilen sayı arasından rastgele seçilen sayının derecesi kadar görüntüyü döndürür.
- width\_shift\_range: Görüntü genişliğini sıfır ile girilen sayının arasından rastgele seçilen sayının yüzdelik değeri kadar yatay kaydırma yapar.
- height\_shift\_range: Görüntü yüksekliğini sıfır ile girilen sayının arasından rastgele seçilen sayının yüzdelik değeri kadar dikey kaydırma yapar.
- shear\_range: Sıfır ile girilen sayının arasından rastgele seçilen sayının derecesi kadar makaslama işlemi yapar.
- zoom\_range: Sıfır ile girilen sayının arasından rastgele seçilen sayının yüzdelik değeri kadar yakınlaşma ve uzaklaştırma işlemi yapar.
- horizontal\_flip: Girilen değer doğrultusunda (True, False) görüntüyü yatay olarak çevirir.
- fill\_mode: Girilen değer doğrultusunda boş kalan pikselleri doldurur.

Elde edilen toplam görüntü sayısından bahsedilecek olursak kullanılan Keras kütüphanesinin "ImageDataGenerator" sınıfı her bir görüntüye dönüşüm işlemleri uygularken "augmented\_data\_count" değişkenini kullanır. Bu değişken belirlenen sayı kadar veri sayısını katlayarak istenen dönüşümleri uygular.

Uygulamanın temel noktası, kullanılan modellerin önceden eğitilmiş olmasıdır. Buna aktarım öğrenmesi (transfer learning) denir. Bu modellere özelleştirilmiş katmanlar eklenerek kullanılan veri

setine daha uygun hale getirilir. Eklenen özelleştirilmiş katmanlardan bahsedebilirsek;

- layers.GlobalAveragePooling2D()(x): Bu katman global ortalama havuzlama ile çıktı boyutunda bir küçülme sağlar. Yapılan bu küçültme ile bilgi kaybını minimize etmek amaçlanır. Aynı zamanda tam bağlı katmanlar için daha uygun bir çıktı boyutu elde edilir.
- layers.Dense()(x): Bu kod ile yeni bir tam bağlı katman eklenir. Bu katmanın içine yazılan değerlere göre işlevi değişir. Yazılan ilk sayı değeri ile katmanın kaç nöronandan oluşacağı belirlenir. Aynı şekilde kullanılan aktivasyon fonksiyon ve regularizasyon tekniği ile birlikte katmanın hangi fonksiyonları ve teknikleri kullanacağı belirlenir. Örneğin aktivasyon fonksiyonu ile negatif ve pozitif girişler düzenlenirken regularizasyon tekniği ile aşırı uyum(overfitting) durumu engellenir.
- layers.Dropout()(x): Bu katman eğitim sırasında rastgele olarak belirlenen bir takım nöronları devre dışı bırakır. Bu işlemin yapılmasının sebebi modelin aşırı uyum durumunu engellemek içindir. Bu teknik ile modelin nöronlara çok fazla bağımlı olması engellenerek daha genel bir öğrenme sağlanır. Çalışmada kullanılan bu katmanlar ile modelin aşırı uyum sağlamasının önüne geçilir. Kullanılan aktivasyon fonksiyonları ile modelin çalışmasındaki doğruluğun artması amaçlanır.

Modelin katmanlarının sonuna ilave edilen bu katmanlar ile modelin aşırı uyum sağlamasının önüne geçilir. Kullanılan aktivasyon fonksiyonları ile modelin çalışmasındaki doğruluğun artması amaçlanır. Özelleştirilmiş katmanların hemen öncesinde dondurma işlemi (freezing) uygulanır. Bu işlemde modelin tüm katmanları dondurulur. Ancak belirli katmanları dondurulduktan sonra serbest bırakılarak yeniden eğitimi yapılır. Duyalandırmak gerekirse tüm katmanları dondur "for layer in basemodel.layers: layer.trainable = False" kodu ile katmanlar sırayla gezilerek eğitilemez olduğu belirtilir ve eğitim sırasında bu katmanların güncellenmemesine sebep olur. Sonrasında eğitilmesi istenen kadar katmayı çözmek için "for layer in base\_model.layers[-20:]: layer.trainable = True" kodundan yararlanılır. Bu kod sonda yirmi katmayı sırayla dolaşarak katmanların tekrar eğitilebilir olduğunu belirtir ve eğitim sırasında güncellenmesini sağlar. Modelden modele eğitilmesi istenen katman sayısı değişiklik gösterebilir. Bu durumda parentez içindeki yirmi sayısını istenen sayı doğrultusunda değiştirmek

yeterli olacaktır. Bu işlemler sonucu modelin aktarım öğrenmesi ile önceden öğrendiği bilgilerden faydalanyılır. Dondurulmayan katmanlar yeniden eğitilerek kullanılan veri setine ve özelliklerine daha uyumlu hale gelir. Sonuç olarak modelin eğitim süresi ve ezberleme riski en aza indirilir. Modelin eğitim aşamasında kullanılan iki metot vardır. İlk öğrenme oranı azaltıcıdır. Bu metot modelin mevcut öğrenme katsayısını ayarlayarak daha performanslı bir eğitim sağlar. İkincisi ise erken durdurma metodudur. Bu metot modelin eğitimi sırasında seçilen parametrenin eğitim süresi boyunca takip edilmesini ve belirlenen devir (epoch) içerisinde gelişim göstermediği takdirde eğitimin durdurulmasını sağlar. Ek olarak kullanılan bu modeller birbirleriyle ilişkilendirilebilir. Bunun sonuncunda ortaya çıkan modele hibrit model denir. Hibrit modellerin dikkate değer birçok faydası bulunmaktadır. Bunlar, çoklu özellik çıkarma, genelleştirilmiş öğrenme, ölçülenebilirlik, hesaplama verimliliği ve son olarak daha iyi genelleme yapabilme olarak sıralanabilir.

#### **4. SONUÇLAR VE TARTIŞMA (RESULTS AND DISCUSSION)**

Bu çalışmada AlexNet, VGG19, DenseNet169, InceptionV3, ResNet101 ve MobileNET aktarım

öğrenme modelleri kullanılmıştır. Modeller Keras kütüphanesi kullanılarak modellenmiştir. AlexNet modeli ise PyTorch kütüphanesi kullanılarak kodlanmıştır. Model altyapılarında kullanılan hiper-parametreler Tablo 1'de verilmiştir. Çalışmada geliştirme ortamı olarak Google Colab tercih edilmiştir. Programlama dili olarak Python kullanılmıştır. Kullanılan bütün modellerde aynı geliştirme ortamı, hiper-parametreler ve programlama dili kullanılarak modeller üzerinde adil karşılaştırma yapılmıştır.

Modellerin performans ölçütleri Tablo 2'de verilmiştir. Bu doğrultuda MobileNet %98.67 F1-Skor değerini alarak diğer modellere üstünlük sağlamıştır. Ardından gelen VGG19 modeli %97.89 değerini almıştır. Bunun yanı sıra DenseNet169 ve Alexnet birbirlerine çok yakın F1-Skorları alarak %97.59 ve %97.57 değerlerini elde etmiştir. ResNet101 için F1-Skor değeri %97.00 iken %96.44 F1-skoruyla InceptionV3 en düşük performansı göstermiştir.

Tüm aktarım öğrenme modelleri içerisinde en yüksek başarımı MobileNet verdiği için bu aktarım modeline ait sonuçlar detaylandırılacaktır. Şekil 6'da MobileNet modelinin karışıklık matrisi gösterilmektedir.

**Tablo 1.** Modeller için Hiper-parametreler (Hyper-parameters for models)

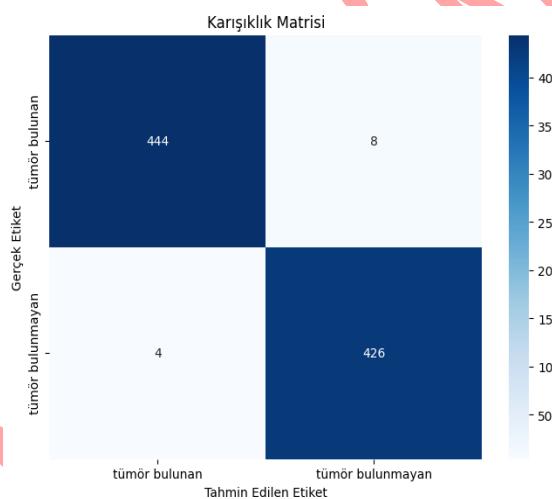
Hiper-parametre	Değer
Optimizasyon Algoritması	Adam
Görüntü Boyutu	128 x 128
Ağırlık	ImageNet (Önceden eğitilmiş tanımlı ağırlıklar)
Kayıp Fonksiyonu	İkili çapraz entropi (Binary crossentropy)
Ölçütler	Doğruluk (Accuracy)
Epoch Sayısı	50
Mini-Batch Boyutu	32
Başlangıç Öğrenme Oranı	0.0001
Düşürme Oranı	0.5

**Tablo 2.** Modellerin Test Sonuçlarının Doğruluk, Hatırlama, Kesinlik ve F1-Skoru Baz Alınarak Karşılaştırılması (Comparison of Models Test Results Based on Accuracy, Recall, Precision and F1-Score)

Model	Doğruluk	Hatırlama	Kesinlik	F1-Skor
<b>MobileNet</b>	<b>%98.63</b>	<b>%98.23</b>	<b>%99.11</b>	<b>%98.67</b>
VGG19	%97.85	%97.57	%98.22	%97.89
DenseNet169	%97.50	%98.67	%96.54	%97.59
AlexNet	%97.62	%96.70	%98.65	%97.57
ResNet101	%96.94	%96.46	%97.54	%97.00
InceptionV3	%96.37	%95.80	%97.09	<b>%96.44</b>

Bu modelden elde edilen F1-Skor değeri %98.67'dir. Model 452 tümör bulunan görüntüden 444 tanesini doğru bir şekilde sınıflandırmaktadır. Gerçekte "tümör bulunan" 8 görüntüyü ise "tümör

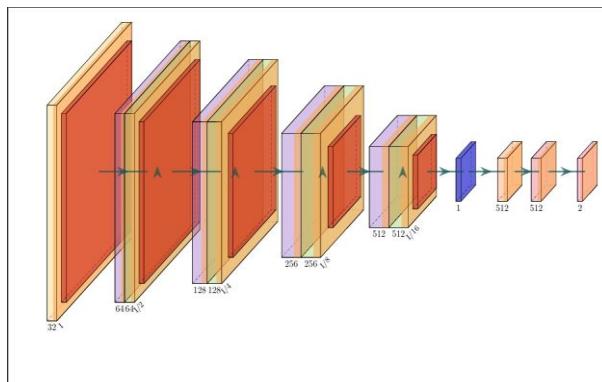
bulunmayan" olarak sınıflandırmıştır. Ayrıca gerçekte "tümör bulunmayan" 4 görüntüyü "tümör bulunan" olarak sınıflandırmıştır. MobileNet modelinin mimarisi Şekil 7'de gösterilmiştir.



**Şekil 6.** MobileNet Modelinin Test Sonuçlarına Göre Karışıklık Matrisi (Confusion Matrix Based on Test Results of The MobileNet Model)

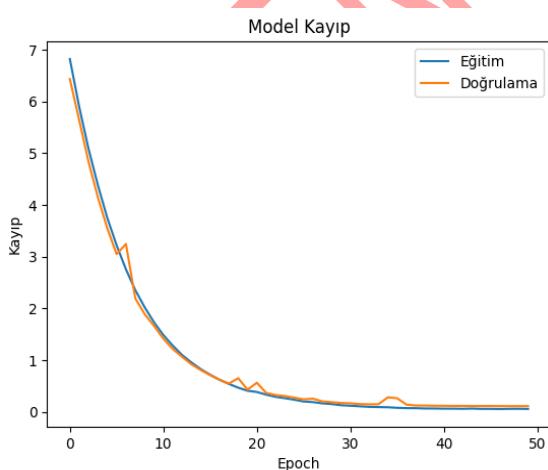
MobileNet'i diğer modellerden ayıran özellikleri vardır. Derin ayrımlı konvülasyonlar kullanarak parametre sayısını ve hesaplama maliyetini önemli ölçüde minimize eder. Diğer modellerin aksine, MobileNet hafif ve verimli bir yapıdadır. Bu sebeple MobileNet mobil ve gömülü cihazlarda kullanıma daha uygundur. Kullanılan diğer modellerdeki yoğun bağlantılar ve artık bloklar gibi yapıları kullanmaz. MobileNet'in yaklaşımı daha

basit ve etkilidir. Diğer modellerdeki karmaşık modüller kullanmaz. Bunun yerine aynı performansı daha az hesaplama kaynağı ile sağlar. Sonuç olarak bu özellikler MobileNet'i diğer modellere göre daha hızlı ve verimli kılar. MobileNet'in beyin tümörü tespitinde oldukça başarılı olması bu özelliklerinden dolayı umut vericidir. Çünkü gömülü veya mobil cihaz tabanlı bir beyin tümörü tespit sistemi tasarlamak istenildiğinde doğrudan entegre edilebilir.



**Şekil 7.** MobileNet Modelinin Mimarisi (Architecture of The MobileNet Model)

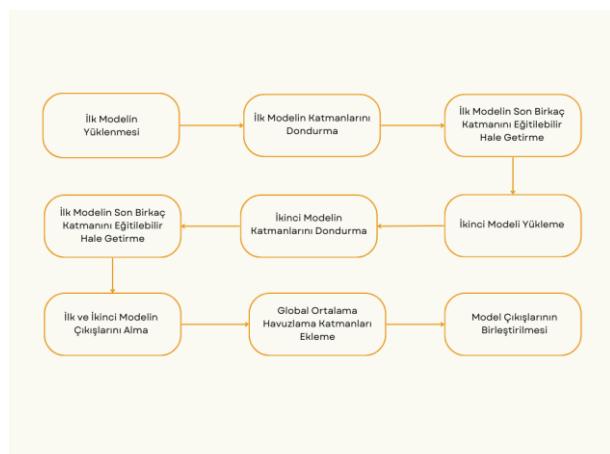
Şekil 8'de MobileNet modelinin değer kayıp grafiği verilmiştir. Bu grafiğin odak noktası olan nokta eğitim ve doğrulama aşamalarındaki kayıp (loss) değerinin devirler (epoch) ile beraber olan değişimidir. Modelin eğitim performansının başarılı ilerlediği görülmektedir. Bunun sebebi ilk birkaç devir içerisinde her iki kayıp değeri de hızla düşüş göstermesinden kaynaklanmaktadır. 5-10. devirler arasında bakıldığına doğrulama kaybı, eğitim kaybindan bir miktar daha düşüktür. Bu kayıp değerleri bize modelin öğrenmediğini göstermektedir. Grafiğe bakıldığında 20. devirden sonra kayıp değerleri istikrarlı hale gelmiştir. Bu modelin verileri iyi öğrendiğini ve öğrenmeyi büyük ölçüde bitirdiğini göstermektedir. Sonuç olarak kayıpların benzer şekilde azalması ve bir süreden sonra istikrarlı olması, modelin eğitim ve doğrulama verileri üzerinde yüksek bir başarı elde ettiği olarak yorumlanabilir.



**Şekil 8.** MobileNet Modelinin Eğitim Değer Kaykı (Training Loss Value of the MobileNet Model)

Tablo 2'de en yüksek F1-skoruna sahip olan üç model birleştirilerek hibrit modeller oluşturulmuştur. Şekil 9'da bir hibrit modelin nasıl çalıştığı gösterilmiştir. Hibrit model hakkında bilgi

vermek gerekirse, hibrit model mimarisi iki veya daha fazla modelin birleştirilmesi ile oluşur. Hibrit model kullanımındaki amaç birbirinden farklı modellerin güçlü yanlarını birleştirerek daha yüksek performanslı ve verimli çalışan bir model elde etmektir. Bu modeller daha çok derin öğrenme veya makine öğrenmesi süreçlerinde kullanılır. Elde edilen model ile tek modelin öğrenme sınırları aşılabilir. Model seçimi yapılırken performans metrikleri ele alınarak birbiri ile en optimal modeller seçilir. Aynı tekli modellerde yapıldığı gibi hibrit modellerde de dondurma işlemi yapılır. Bu yaklaşım ile verimli bir eğitim süreci sağlanır. Model çıktılarının birleştirilmesi birleştirme (concatenation) katmanı ile sağlanır. Bu katman kullanılan modellerin çıktılarını üç uca ekleyerek birden fazla modelin birbirinden farklı özelliklerinin bir araya getirilmesi ile daha genel ve güçlü bir temsiliyet sağlar. Farklı modellerin birleştirilmesi ile sağlanan çeşitliliğin faydası ise hata toleransı ve aşırı uyum (overfitting) gibi sorunları minimize etmektir.



**Şekil 9.** VGG19-Densenet169 Modelinin Hibritlendiği Örnek Model (An Example of Hybridizing VGG19-Densenet169 Model)

Hibrit modellerden elde edilen başarımlar ölçütleri Tablo 3'te verilmiştir. Hibrit VGG19-DenseNet169 modeli F1-Skoru metriğine göre %99.22 ile en yüksek başarımlar elde edilmiştir. Öte yandan Hibrit VGG19-MobileNet ve Hibrit Dense169-MobileNet modelleri sırasıyla F1-Skoru metriğine göre %98.89 ve %98.67 başarımlarını vermiştir. Tablo 2'de verilen sonuçlar göz önünde bulundurulduğunda sınıflandırma başarımları arasında %2 ile %3 arasında

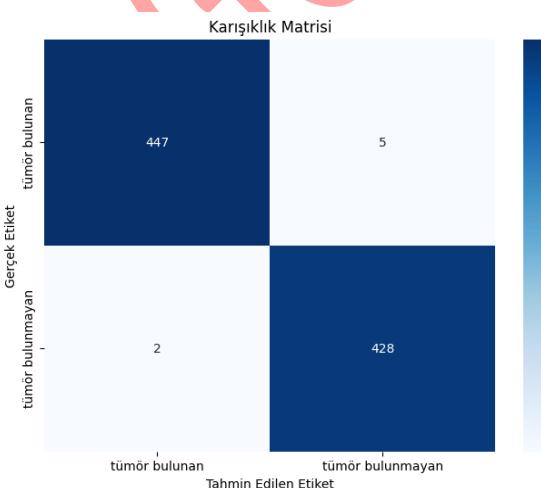
iyileştirme yapılmıştır. Örneğin MobileNet tek başına kullanıldığında F1-Skoru metriğine göre %98.67 başarımlar verirken, VGG19 tek başına kullanıldığında F1-Skoru metriğine göre %97.89 başarımlar vermiştir. Ancak bu iki model birleştirildiğinde F1-Skoru metriğine göre %98.89 başarımlar elde edilmiştir. Her iki modelinde başarımları bu durumda artış göstermiştir. Bu artış diğer hibrit model sonuçlarında da görülmektedir.

**Tablo 3.** Hibrit Modellerin Test Sonuçlarının Doğruluk, Hatırlama, Kesinlik ve F1-Skoru Baz Alınarak Karşılaştırılması (Comparison of Test Results Hybrid Models Based on Accuracy, Recall, Precision and F1-Score)

Model	Doğruluk	Hatırlama	Kesinlik	F1-Skor
<b>Hibrit VGG19-DenseNet169</b>	<b>%99.21</b>	<b>%98.89</b>	<b>%99.55</b>	<b>%99.22</b>
Hibrit VGG19-MobileNet	%98.87	%98.67	%99.11	%98.89
Hibrit Dense169-MobileNet	%98.6	%98.67	%98.67	%98.67

Şekil 10'da hibrit VGG19-DenseNet169 modelinin karışıklık matrisi gösterilmektedir. Bu modelden elde edilen F1-skor değeri %99.22 ile tüm deneylerden elde edilen en yüksek başarımların değeridir. Model 452 tümörlü görüntünden 447

tanesini doğru etiketlemektedir. Buna karşın gerçekte "tümör bulunan" 5 görüntüyü "tümör bulunmayan" olarak sınıflandırmıştır. Ayrıca gerçekte "tümör bulunmayan" 2 görüntüyü "tümör bulunan" olarak sınıflandırmıştır.



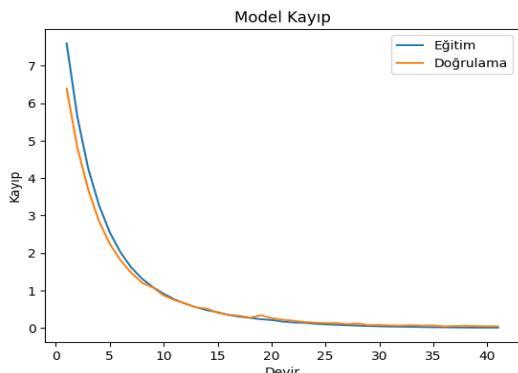
**Şekil 10.** Hibrit VGG19-DenseNet169 Modelinin Test Sonuçlarına Göre Karışıklık Matrisi (Confusion Matrix Based on Test Results of Hybrid VGG19-DenseNet169 Model)

Hibrit VGG19-DenseNet169 modeli derin özellik çıkarımı alanında kuvvetlidir. VGG19'un derin ve geniş katman yapısı güçlü özellikler çıkarmasını sağlarken, DenseNet169'un yoğun bağlantıları bilgi akışında iyileştirme sağlar. Her iki modelin güçlü yönleri birleştirilerek iyileştirilmiş bir model elde edilir. Bu da modelin doğruluğunu artırmaktadır.

Şekil 11'de hibrit VGG19-DenseNet169 modelinin değer kayıp grafiği verilmiştir. 0-10. devirler arasına bakıldığından doğrulama kaybı, eğitim kaybından bir miktar daha düşüktür. Bundan yola çıkararak modelin iyi bir genelleme yaptığı söylenebilir. Grafiğe bakıldığından yaklaşık 20. devirden sonra kayıp değerleri istikrarlı hale gelmiştir. Bu modelin devam eden devirlerinin

önemli bir ölçüde iyileşme sağlamadığını göstermektedir. Sonuç olarak kayıpların benzer şekilde azalması ve bir süreden sonra oturtulmuş olması, modelin eğitim ve doğrulama verileri üzerinde yüksek bir başarı elde ettiğini gösterir.

yaklaşımın sonuçlarının literatürdeki sonuçlar ile rekabet ettiği görülmektedir.



**Şekil 11.** Hibrit VGG19-DenseNet169 Modelinin Eğitim Değer Kaybı (Training Loss Value of the Hybrid VGG19-DenseNet169 Model)

#### 4.1. Önceki Çalışmalar ile Kyaslama (Comparison with Previous Studies)

Tablo 4'te beyin tümör görüntülerü üzerinde yapılan çalışmalar karşılaştırmalı olarak verilmiştir. Tablo 4 incelendiğinde araştırmacıların kullandıkları veri kümeleri ve veri kümelerinde yer alan dağılımların oldukça farklılık gösterdiği gözlemlenmektedir. Bu nedenle çalışmalarında elde edilen sonuçların karşılaştırmasını anlamlı yapabilmek için veri kümeleri biraz daha detaylı yazılmıştır. Tablo 4 incelendiğinde beyin tümörü sınıflandırmasında elde edilen en yüksek başarım doğruluk metriğine göre %100 olarak raporlanmıştır [20]. Çalışma [20]'de araştırmacılar InceptionV3 aktarım öğrenmesi teknini uygulayarak bu sonucu elde etmektedirler. Karşılaştırma tablosunda yer alan en yüksek ikinci başarım ise bu çalışmadan elde edilen %99.22 sonucudur. Bizim sonucumuza en yakın sonuç ise çalışma [19]'da verilen %99.15 sonucudur. Bu üç çalışmada ikili bir sınıflandırma problemi ele alınmıştır. Sadece çalışma [19, 20]'de doğruluk metriği değerlendirme metriği olarak tercih edilmiştir. [8, 9, 11, 14, 16, 18, 24] çalışmalarında da ikili sınıflandırma problemi ele alınmıştır. Ancak bu çalışmada elde edilen sonuç bunlara göre daha yüksektir. Çalışma [13]'te üç sınıflı bir problem ele alınırken, çalışma [21]'de ise 4 sınıflı bir problem ele alınmaktadır. Bunlara ek olarak karşılaştırma tablosunda yer alan diğer çalışmalar ise beyin tümörü segmentasyonu ile ilgilidir. Karşılaştırma tablosunda yer alan sonuçlar birlikte değerlendirildiğinde önerdiğimiz

ORJİNAL

**Tablo 4.** Önceki Çalışmalar ile Kıyaslama (Comparison with Previous Studies)

Referans No	Veri Kümesi	Kullanılan Yöntemler	Değerlendirme Metriği	Elde Edilen Sonuç
[6]	Kaggle platformundan alınan veri kümesi kullanılmıştır. Ancak görüntü sayısı hakkında detaylı bilgi verilmemiştir.	Görüntü işleme + SVM	Kesinlik	0.92
[7]	BRATS 2013'ün bir uzantısı olan BRATS 2015 klinik veri seti kullanılmıştır. Yüksek dereceli glioma hastalarından 30 rastgele görüntü ve düşük dereceli glioma hastalarından 10 rastgele ile deneyler gerçekleştirilmiştir.	MAP-EM + K-ortalamalar algoritması	Dice	0.92
[8]	Farklı veri kümelerinden görüntüler bir araya getirilerek 4222 görüntü üzerinde deneyler yapılmıştır. Bu görüntülerin 3334 tanesi tümör içeren görüntü iken 888 tanesi ise tümör içermeyen görüntündür.	CNN	F1-skor	0.9474
[9]	400 tane görüntü bulunmaktadır. Bunlardan 230 tanesi tümörlü görüntüden oluşmaktadır. Geri kalan 170 görüntü ise tümör içermemektedir.	CNN	F1-skor	0.89
[10]	Eğitim kümesinde 285 farklı hastanın görüntüsü bulunmaktadır. Doğrulama kümesinde ise BRATS 2017 ve BRATS 2018'den bilinmeyen derecelere sahip 46 ve 66 hastanın görüntülerleri vardır.	Çoklu görünüm füzyon ağları	Dice	0.895
[11]	Normal tümör ve anomal tümör olarak etiketli veri kümesi kullanılmıştır. Ancak veri kumesinin dağılımı hakkında bilgi verilmemiştir.	Görüntü işleme + SVM	Doğruluk	%97
[13]	Çevrimiçi ücretsiz erişime sahip Çin'deki iki hastaneden alınan veri kümesi kullanılmıştır. Bu görüntüler 2005 ile 2010 yılları arasında 233 hastadan alınmıştır. Bu veri seti 3064 dilimden oluşmaktadır. Veri kümesi 708 menenjiyom, 1426 gliyom ve 930 hipofiz tümörü olarak kategorilere ayrılmıştır.	Çoklu Görev U-Net mimarisı	Doğruluk	%97
[14]	152 tanesi normal tümör 104 tanesi ise anormal tümör olarak etiketli veri kümesi kullanılmıştır.	CNN	F1-skor	0.981
[15]	BraTS 2020 veri kümesi kullanılmıştır. Ancak veri kumesinin dağılımı hakkında net bir sayı verilmemiştir.	U-net	Dice	%86
[16]	1992 tane görüntü kullanılmıştır. Bu görüntülerin 1494 tanesi eğitim için 498 tanesi (273 tane tümör içeren, 225 tanesi tümör içermeyen) ise test için kullanılmıştır.	FastAi temelli CNN	Doğruluk	%95.78
[17]	30 hasta görüntüsünü içeren BRATS veri kümesi kullanılarak deneyler gerçekleştirilmiştir.	Watershed böülütleme algoritması + CNN	Dice	%93.5
[18]	25 tane görüntünden oluşan veri kümesi kullanılmıştır. Bunlardan 98'i beyin tümörü içermezken 155 tanesi ise tümörlü görüntündür.	ResNet-50	F1-skor	0.9795
[19]	5327 görüntü kullanılmıştır. Bunlardan 2519 tanesi tümör içermeyen görüntülerken 2808 tanesi ise tümör içeren görüntülerdir.	CNN	Doğruluk	%99.15
[20]	102 adet tümörsüz görüntü ve 118 adet tümörlü görüntü eğitim için kullanılmıştır. 40 tümörsüz görüntü ve 44 adet tümörlü görüntü test için kullanılmıştır.	InceptionV3	Doğruluk	%100
[21]	3264 adet görüntünden oluşan veri kümesi kullanılmıştır. Bunlardan 2870 tanesi eğitim için geriye kalan 394 tanesi test için kullanılmıştır. Veri kumesindeki etiketlerin dağılımı ise 500 tümörsüz,	CNN + AlexNet	F1-skor	0.9275

	926 glioma beyin tümörü, 937 menenjiyom beyin tümörü ve 901 hipofiz beyin tümörü şeklindedir.			
[22]	5000 adet görüntü üzerinde deneyler gerçekleştirilmiştir.	YOLOv5x	F1-skor	0.87
[23]	REMBRANDT veri kümelerinden 99 hastanın MR görüntüleri alınarak deneyler gerçekleştirilmiştir. Her hasta için ise 30'a yakın MR görüntüsü olduğu raporlanmıştır.	SVM	F1-skor	0.90
[24]	253 görüntü kullanılmıştır. Bu görüntülerin 155 tanesi tümörlü iken 98 tanesi ise tümörsüz görüntündür.	KNN + derin sinir ağları öznitelikleri	Doğruluk	%89.72
Önerilen hibrit VGG19+ DenseNet169	2938 tane beyin MR görüntüsü ile deneyler yapılmıştır. Bunların 1491 tanesi tümör olmayan beyin görüntüsü, 1447 tanesi ise tümörlü beyin görüntüsüdür.	VGG19+DenseNet169	F1-skor	%99.22

## 5. GENEL DEĞERLENDİRMELER ve GELECEK ÇALIŞMALAR (GENERAL EVALUATIONS AND FUTURE WORKS)

Bu çalışmada yapılan deneyler incelendiğinde MobileNet modelinin diğer modellerden (VGG-19, Resnet101, Densenet169, InceptionV3, Alexnet) daha yüksek F1-Skor değerine ulaştığı görülmektedir. Kullanılan hibrit modellerde (VGG19-DenseNet169, VGG19-MobileNet, Dense169-MobileNet) ise en yüksek F1-Skor değeri VGG19-DenseNet169 modeli ile elde edilmiştir. MobileNet'i diğer modellerden ayıran temel özelliği derin ayrımlı konvülasyonlar kullanmasıdır. Bu özelliği modele parametre sayısında ve hesaplama maliyetinde kayda değer biçimde düşüşe sebebiyet verir. VGG19'un düşük seviyeli özellikleri iyi yakalaması ve DenseNet169 modelinin karmaşık özellikleri yakalamada iyi olması gibi özelliklerin kombinasyonuyla VGG19-DenseNet169 hibrit modeli tüm test edilen modeller arasında en başarılı model olmuştur. Modellerin birleştirilmesi ile sınıflandırma başarılarında artış olduğu gösterilmiştir. Tüm sonuçlar incelendiğinde en başarılı modelden %99'un üzerinde sınıflandırma başarımı elde edilmiştir. Gelecekteki çalışmalarında MobileNet modelinin mimarisinde modifikasyonlar ve hiper parametre optimizasyonu yapılarak sınıflandırma başarımının iyileştirilmesi planlanmaktadır. Ayrıca farklı görüntü sınıflandırma problemlerinde önerilen hibrit aktarım öğrenmesi mimarilerinin denenmesi düşünülmektedir.

## ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarı çalışmalarında kullandıkları meryal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirdiğini beyan ederler.

The author of this article declares that the materials and methods they use in their work do not require ethical committee approval and/or legal-specific permission.

## YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Yazarlar çalışmaya eşit oranda katkı sağlamıştır.

The authors have contributed equally to the work.

## ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

There is no conflict of interest in this study.

## KAYNAKLAR (REFERENCES)

- [1] Abd El Kader I, Xu G, Shuai Z, Saminu S, Javaid I, Salim Ahmad I. Differential deep convolutional neural network model for brain tumor classification. Brain Sciences. 2021; 11(3): 352.
- [2] Logeswari T, Karnan M. An improved implementation of brain tumor detection using segmentation based on hierarchical self organizing map. International Journal of Computer Theory and Engineering. 2010; 2(4): 591.
- [3] El-Dahshan ESA, Mohsen HM, Revett K, Salem AM. Computer-aided diagnosis of human brain tumor through MRI: A survey and a new algorithm. Expert Systems with Applications. 2014; 41(11): 5526–5545.
- [4] Chahal PK, Pandey S, Goel S. A survey on brain tumor detection techniques for MR

- images. *Multimedia Tools and Applications*. 2020; 79(29): 21771–21814.
- [5] Ari A, Alcin OF, Hanbay D. Brain MR image classification based on deep features by using extreme learning machines. *Biomedical Journal of Scientific and Technical Research*. 2020; 25(3).
- [6] Varshney S, Prajapati SK, Rajput S, Kaur M, Rakesh N, Goyal MK. Image processing based brain tumor detection. In: 2022 International Conference on Fourth Industrial Revolution Based Technology and Practices (ICFIRTP); 2022. p. 204–209. IEEE.
- [7] Anwar SM, Yousaf S, Majid M. Brain tumor segmentation on multimodal MRI scans using EMAP algorithm. In: 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 2018. p. 550–553. IEEE.
- [8] Methil AS. Brain tumor detection using deep learning and image processing. In: 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS); 2021. p. 100–108. IEEE.
- [9] Hashan AM, Agbozo E, Al-Saeedi AAK, Saha S, Haidari A, Rabi MNF. Brain tumor detection in MRI images using image processing techniques. In: 2021 4th International Symposium on Agents, Multi-Agent Systems and Robotics (ISAMSR); 2021. p. 24–28. IEEE.
- [10] Noori M, Bahri A, Mohammadi K. Attention-guided version of 2D UNet for automatic brain tumor segmentation. In: 2019 9th International Conference on Computer and Knowledge Engineering (ICCKE); 2019. p. 269–275. IEEE.
- [11] Sravanthi N, Swetha N, Devi PR, Rachana S, Gothane S, Sateesh N. Brain tumor detection using image processing. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*. 2021; 7(3): 348–352.
- [12] Malik M, Jaffar MA, Naqvi MR. Comparison of brain tumor detection in MRI images using straightforward image processing techniques and deep learning techniques. In: 2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA); 2021. p. 1–6. IEEE.
- [13] Kordnoori S, Sabeti M, Shakoor MH, Moradi E. Deep multi-task learning structure for segmentation and classification of supratentorial brain tumors in MR images. *Interdisciplinary Neurosurgery*. 2024; 36: 101931.
- [14] Gurunathan A, Krishnan B. Detection and diagnosis of brain tumors using deep learning convolutional neural networks. *Int J Imaging Syst Technol*. 2021;31(3):1174–1184.
- [15] Eker AG, Duru N. Medikal görüntü işlemede derin öğrenme uygulamaları. *Acta Infologica*. 2021;5(2):459–474.
- [16] Dipu NM, Shohan SA, Salam KMA. Deep learning based brain tumor detection and classification. In: Proceedings of the 2021 International Conference on Intelligent Technologies (CONIT); 2021; 1–6. IEEE.
- [17] Jemimma TA, Vetharaj YJ. Watershed algorithm based DAPP features for brain tumor segmentation and classification. In: Proceedings of the 2018 International Conference on Smart Systems and Inventive Technology (ICSSIT); 2018; 155–158. IEEE.
- [18] Periasamy JK, Buvana S, Jeevitha P. Comparison of VGG-19 and RESNET-50 Algorithms in Brain Tumor Detection. In: Proceedings of the 2023 IEEE 8th International Conference for Convergence in Technology (I2CT); 2023; 1–5. IEEE.
- [19] Kumar T, Yadav PK, Yadav V. Detection of Brain Tumor using CNN. In: Proceedings of the 2022 4th International Conference on Inventive Research in Computing Applications (ICIRCA); 2022; 1121–1126. IEEE.
- [20] Prakash RM, Kumari R. Classification of MR brain images for detection of tumor with transfer learning from pre-trained CNN models. In: Proceedings of the 2019 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET); 2019; 508–511. IEEE.
- [21] Khofiya SN, Fu’adah YN, Pratiwi NKC, Naufal RI, Pratama AD. Brain Tumor Classification Based On MRI Image Processing With Alexnet Architecture. In: Proceedings of the 2022 IEEE Asia Pacific Conference on Wireless and Mobile (APWiMob); 2022; 1–6. IEEE.
- [22] Kumar M, Pilania U, Bhayana T, Thakur S. Utilizing YOLOv5x for the Detection and Classification of Brain Tumors. In: Proceedings of the 2024 2nd International Conference on Disruptive Technologies (ICDT); 2024; 1343–1348. IEEE.
- [23] Çınarer G, Emiroğlu BG. Classification of brain tumors by machine learning algorithms. In: Proceedings of the 2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT); 2019; 1–4. IEEE.

- [24] Aslan M. Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti. Fırat Üniv Mühendislik Bilimleri Derg. 2022;34(1):399–407.
- [25] Google. Google colab, 2017, <https://colab.google/>
- [26] Guido Van Rossum and Fred L Drake Jr. Python reference manual. Centrum voor Wiskunde en Informatica Amsterdam, 1995.
- [27] Keras Team. Keras: Deep Learning for humans, <https://keras.io/>
- [28] OpenCV. The OpenCV Reference Manual, 2.4.13.7 edition, April 2014.
- [29] Facebook. Pytorch, 2016, <https://pytorch.org/>
- [30] Brain Tumor — kaggle.com. <https://www.kaggle.com/datasets/jakeshbohaju/brain-tumor/data>, [Son erişim tarihi 06-01-2024].
- [31] Er MB. Akciğer Seslerinin Derin Öğrenme ile Sınıflandırılması. Gazi University Journal of Science Part C: Design and Technology. 2020;8(4):830–844.
- [32] Ali Ö. Automatic Detection of Epileptic Seizures from EEG Signals Using Artificial Intelligence Methods. Gazi University Journal of Science Part C: Design and Technology. 2024; 257–266.

ERKEN GÖRÜNMÜ