



# ULUBORLU MESLEKİ BİLİMLER DERGİSİ (UMBD)

Uluborlu Journal of Vocational Sciences

<http://dergipark.gov.tr/umbd>

## BEYİN TÜMÖRÜ MR GÖRÜNTÜLERİNİN EVRİŞİMSEL SİNİR AĞLARI İLE SINIFLANDIRILMASI

Arife Dal<sup>1\*</sup>, Berat Eliaçık<sup>2</sup>, Ali Hakan Işık<sup>3</sup>

<sup>1\*2,3</sup>Mehmet Akif Ersoy Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Burdur, Türkiye.

\*Sorumlu Yazar: arifedal@outlook.com.tr

(Geliş/Received: 27.05.2023; Kabul/Accepted: 21.06.2023)

**ÖZET:** Yapay zekâ, tıbbi görüntüleme dahil olmak üzere çeşitli sağlık alanlarında giderek daha önemli hale gelmektedir. Hastalık tespiti, teşhisi ve tedavi planlamasının doğruluğunu, hızını artırma potansiyeline sahiptir. Özellikle, derin öğrenme modelleri, büyük veri kümelerinden karmaşık özellikleri otomatik olarak öğrenerek tıbbi görüntü analizinde umut verici sonuçlar göstermektedir. Bu çalışma, farklı derin öğrenme modellerinin beyin tümörlerinin MRI taramalarındaki performansını değerlendirmekte, elde edilen performans sonuçlarını sunmaktadır. Çalışmada veri kümesi 'Tümör Yok', 'Hipofiz Tümörü', 'Meningioma Tümörü' ve 'Glioma Tümörü' olmak üzere dört sınıftan oluşmaktadır. Çalışmada, veri seti beş farklı model kullanarak eğitilmiştir. Bu modeller EfficientNet, ResNet, VGG-16, Inception-V3 ve DenseNet'tir. Bu modellerin performansı test edilmiştir ve sonuçlar görselleştirilerek analiz edilmiştir. Elde edilen sonuçlar, derin öğrenme modellerinin beyin tümörlerini MR görüntülerinden sınıflandırmada umut verici bir performansa sahip olduğunu, birçok modelin %90'ın üzerinde doğruluk oranlarına ulaştığını göstermektedir. Ancak daha detaylı incelendiğinde EfficientNet %96 oranla doğruluk, tümör yok sınıfı için %94 oranla f1-skor, %94 oranla kesinlik, %94 oranla duyarlılık, glioma tümör için %99 oranla f1-skor, %100 oranla kesinlik, %99 oranla duyarlılık göstermiştir. ResNet ise %98 oranla doğruluk, tümör yok sınıfı için %97 oranla f1-skor, %99 oranla kesinlik, %95 oranla duyarlılık glioma tümör için %100 oranla f1-skor, %100 oranla kesinlik, %100 oranla duyarlılık göstermiştir. Bu oranlara bakıldığında EfficientNet ve ResNet modellerinin özellikle 'Tümör Yok' ve 'Glioma Tümör' sınıflarında en yüksek performansı gösterdiği görülmektedir. Bu nedenle, bu modeller bu uygulama için en uygun modeller olarak kabul edilmektedir. Genel olarak, bu çalışma, beyin tümörü MR görüntüleme farklı derin öğrenme modellerinin performansına ilişkin değerli bilgiler sağlar, bu alanda gelecekteki araştırmalara bilgi vermektedir.

**Anahtar kelimeler:** Beyin Tümörü, EfficientNet, Evrişimli Sinir Ağları, ResNet, Sınıflandırma, Tespit

## CLASSIFICATION OF BRAIN TUMOR MR IMAGES WITH CONVOLUTIONAL NEURAL NETWORKS


**ABSTRACT:** Artificial intelligence is becoming increasingly important in various healthcare fields, including medical imaging. It has the potential to increase the accuracy and speed of disease detection, diagnosis and treatment planning. In particular, deep learning models show promising results in medical image analysis by automatically learning complex features from large datasets. This study evaluates the performance of different deep learning models in MRI scans of brain tumors and presents the performance results obtained. The dataset in the study consists of four classes: 'No Tumor', 'Pituitary Tumor', 'Meningioma Tumor' and 'Glioma Tumor'. In the study, the dataset was trained using five different models. These models are EfficientNet, ResNet, VGG-16, Inception-V3 and DenseNet. The performance of these models has been tested and the results visualized and analyzed. The results show that deep learning models have promising performance in classifying brain tumors from MR images, with many models reaching accuracy rates of over 90%. However, when examined in more detail, EfficientNet is 96% accuracy, 94% f1-score for no tumor class, 94% accuracy, 94% sensitivity, 99% f1-score for glioma tumor, 100% accuracy, 99% sensitivity has shown. On the other hand, ResNet showed 98% accuracy, 97% f1-score, 99% precision, 95% sensitivity, 100% f1-score for glioma tumor, 100% precision, 100% sensitivity for the no tumor class. Considering these ratios, it is seen that the EfficientNet and ResNet models show

the highest performance especially in the 'No Tumor' and 'Glioma Tumor' classes. Therefore, these models are considered the most suitable models for this application. Overall, this study provides valuable insights into the performance of different deep learning models in brain tumor MR imaging, informing future research in this area.  
**Keywords:** Brain Tumor, EfficientNet, Convolutional Neural Networks, ResNet, Classification, Detection

## 1. GİRİŞ


Bir beyin tümörü, beyninizdeki anormal hücrelerin bir kitlesi veya büyümesidir. Beyin tümörleri beyninizde başlayabilir (birincil beyin tümörleri) veya kanser vücudunuzun diğer bölgelerinde başlayabilir ve ikincil (metastatik) beyin tümörleri olarak beyninize yayılabilmektedir. Bir beyin tümörünün ne kadar hızlı büyüdüğü büyük ölçüde değişmektedir. Büyüme hızı ve beyin tümörünün yeri, sinir sisteminin işlevini nasıl etkileyeceğini belirlemektedir [1].

Beyin tümörü genel olarak ikiye ayrılmaktadır. Bazı beyin tümörleri kanserli değildir (iyi huylu) ve bazı beyin tümörleri kanserlidir (kötü huylu). İyi huylu tümör, yavaş üreme hızına sahiptirler. Ayrıca beyin dokusundan kolaylıkla ayrılabilirler ve tümü veya tümüne yakın kısmı çıkarılabilmektedir [2]. Bu nedenle ameliyat sonrası iyi sonuçlar alınmaktadır. Bazen iyi huylu tümörlerin hepsi çıkarılamadığı takdirde bölgesel ışın tedavisi uygulanabilmektedir. Kötü huylu tümör, anormal veya hızla büyüyen beyin tümörleri olup hızla büyüdüğü için sağlıklı beyin hücrelerinin içerisine yayılmaktadırlar. Bu tümörlerin tedavi sonuçları tümörün yerleşimine, genişliğine, beraberindeki risk faktörlerine bağlı olarak değişmekle birlikte yaşam süresi uzatılmaktadır [3]. Miami Nöroloji Merkezi'nin araştırmasına göre, Amerika Birleşik Devletleri'nde 100.000 kişi başına yaşa göre ayarlanan ABD ortalama insidansı Meningioma (7.61), Hipofiz (3.29), Glioblastoma (3.19) bu üç tümör çeşidinin en sık görülen tümör çeşitleri olduğunu doğrulamıştır [4]. Gliomalar, merkezi sinir sistemi (beyin veya omurilik) ve periferik sinir sistemindeki çeşitli glial hücrelerden (nöroglia) oluşan tümörlerdir. Glial hücreler, sinir sistemi boyunca elektrik sinyallerini ve bilgileri ileten nöronları çevreledikleri, yalıtıtları, besledikleri, tamirettikleri ve korudukları için "destekleyici hücreler" olarak adlandırılmaktadır ve kötü huylu tümördür [5]. Şekil 1'de örnek bir glioma tümör MRI görüntüsü verilmiştir.



Şekil 1. Glioma MRI Görüntüsü

Şekil 2'de görüldüğü üzere, meningioma, beynin meninkslerinde bir menenjiyom gelişir ve leptomeningeal kökenli iyi huylu bir tümördür.

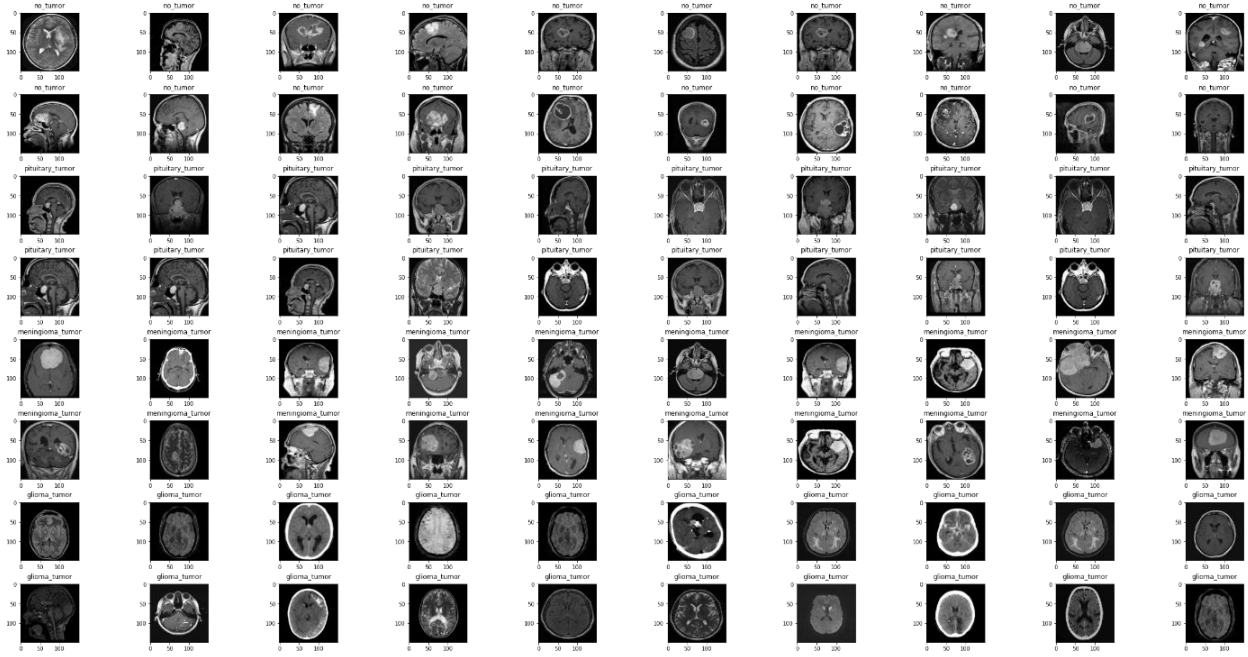


Şekil 2. Meningioma MRI Görüntüsü

Şekil 3'te görülen hipofiz tümörü, hipofiz bezinin ön gövdesinde meydana gelmektedir. Bu, burnunuzun köprüsünün arkasında bulunan bezelye büyüklüğünde bir bezdir. Diğer endokrin bezlerin işlevlerini düzenlemeye yardımcı olan hormonları üretir ve iyi huylu bir tümördür [6].



Şekil 3. Hipofiz MRI Görüntüsü



Şekil 4. Veri kümesinde bazı MRI görüntülerinin çizimi

Şekil 4’te örnek olması amacıyla veri kümesinden bazı MRI görüntüleri verilmiştir.

## 2. LİTERATÜR TARAMASI

Literatürdeki çalışmalara bakıldığında beyin tümör teşhisi ve sınıflandırılması ile ilgili yöntemler ve teknikler incelenmiştir. Yapılan literatür araştırmasında derin öğrenme veya makine öğrenme algoritmalarıyla beyin tümör sınıflandırılması ve beyin tümörü ile ilgili çalışmalar arasında şunlar gösterilebilir;

MRG görüntüler ile beyin tümörlerinin tespiti için MobilNetV2 derin öğrenme modeli ile birlikte k en yakın komşu (k-EYK) algoritması kullanılmıştır. Çalışmada, öznelik olarak önceden eğitilmiş MobileNetV2 modelinin tam bağlantı katman değerleri kullanılmıştır. Elde edilen özneliklerin sınıflandırılmasında daha yüksek performansından dolayı k-EYK algoritması kullanılmıştır. Yapılan deneysel çalışmalarda, önerilen yöntem ile beyin tümörlerinin tespitinde %96,5 doğruluk skoruna ulaşılmıştır. Aynı veri setinin kullanıldığı literatürdeki diğer bazı çalışmalar ile karşılaştırıldığında daha yüksek bir başarımla sağlanmıştır [7].

Beyin MR görüntülerinden otomatik tümör tespiti ve sınıflandırma yapabilen beş farklı BDOTS (Bilgisayar Destekli Otomatik Tespit Sistemleri) tasarlanmış, 6 farklı veri tabanı kullanılarak tasarlanan BDOTS’ların performansı değerlendirilmiştir ve başarılı sonuçlar elde edilmiştir. Bu sistemler, tümörlerin özelliklerine göre sınıflandırma yapabilmektedir [8].

Üç farklı beyin tümörünün (gliyom, menenjiyom ve hipofiz bezi) T1 ağırlıklı MR görüntüleri üzerinde evrişimsel sinir ağı (ESA) kullanılarak sınıflandırılması ve aksiyel, koronel ve sagittal MR kesitlerinin sınıflandırmadaki etkinliğinin belirlenmesi amaçlanmıştır. Eğitilen ESA’nın tam bağlantılı ilk katmanından elde edilen öznelikler, destek vektör makinesi (DVM), k en yakın komşu (kNN) ve Bayes yöntemleriyle de sınıflandırılmıştır. Raporlara göre ESA, ve ESA tabanlı DVM, kNN ve Bayes sınıflandırıcılarının elde ettiği doğruluk değerleri sırasıyla 0.9860, 0.9979, 0.9907 ve 0.8933’ dür [9].

Manyetik rezonans (MR) görüntüleme beyin tümörlerinin tanı ve teşhisinde önemli bir role sahiptir. Bununla birlikte, MR görüntüleri kullanarak beyin tümörlerini sınıflandırması beyin yapısının karmaşıklığı ve içindeki dokuların iç içe geçmesi nedeniyle zordur. Bu çalışma, DenseNet201 ön eğitilmiş modelinin avg\_pool ve fc1000 katmanlarından elde edilen 2920 özneteliğin 500 adet mRMR algoritması kullanılarak seçilmiştir. Öznetelik seçimi yapılmadan %95,00 doğruluk, mRMR öznetelik seçimi yapılarak %95,76 doğruluk elde edilmiştir [10].

Figshare Cheng aracılığıyla halka açık 3064 görüntüden oluşan bir beyin tümörü veri kümesi CNN modeli üzerinde eğitilmiştir. Önerilen CNN mimarisi ile Figshare veri seti üzerindeki beyin tümörlerini (glioma, meningioma veya hipofiz) sınıflandırmada ortalama %96,95 doğrulukla başarı göstermiştir ve CNN mimarisini literatürde ki birçok araştırma sonucuna göre yüksek performans gösterdiği görülmüştür [11].

Farklı BESA mimarileri tasarlanarak Benchmark, Rembredant ve Harvard veri setleri üzerinde test edilmiştir. Elde edilen en yüksek doğruluk değeri %99,10 ile BESA4 mimarisi ve Benchmark veri setinden elde edilmiştir. En yüksek ortalama doğruluk ise yine BESA4 mimarisi ile %98,66 olarak hesaplanmıştır [12].

Devlet hastanelerinden MR görüntüleri alınarak Markov Random Field (MRF), Kapur, Kittler ve Otsu algoritmaları ile MR görüntülerindeki tümörlü bölgeler tespit edilmeye çalışılmıştır. Algoritmalar, MR görüntülerinin daha önceden belirlenmiş bölgelerine (ROI – Region of Interest) ayrı ayrı uygulanmıştır. Yapılan deneysel uygulamada Markov Random Field (MRF) algoritmasının beyin tümörü tespitinde diğer algoritmalara oranla daha başarılı sonuçlar verdiği gözlemlenmiştir [13].

Yapılan çalışmada beyin kanserine neden olan glioma, meningioma ve hipofiz görüntülerine ilave olarak beyin tümörüne rastlanmayan görüntüleri de içeren açık kaynaklı bir veriseti kullanılmıştır.

Geliştirilen modelin başarısını ölçmek için kullanılan veriseti üzerinde VGG-19 mimarisi kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma sonucunda geliştirilen model %95 doğruluk oranı elde etmiştir [14].

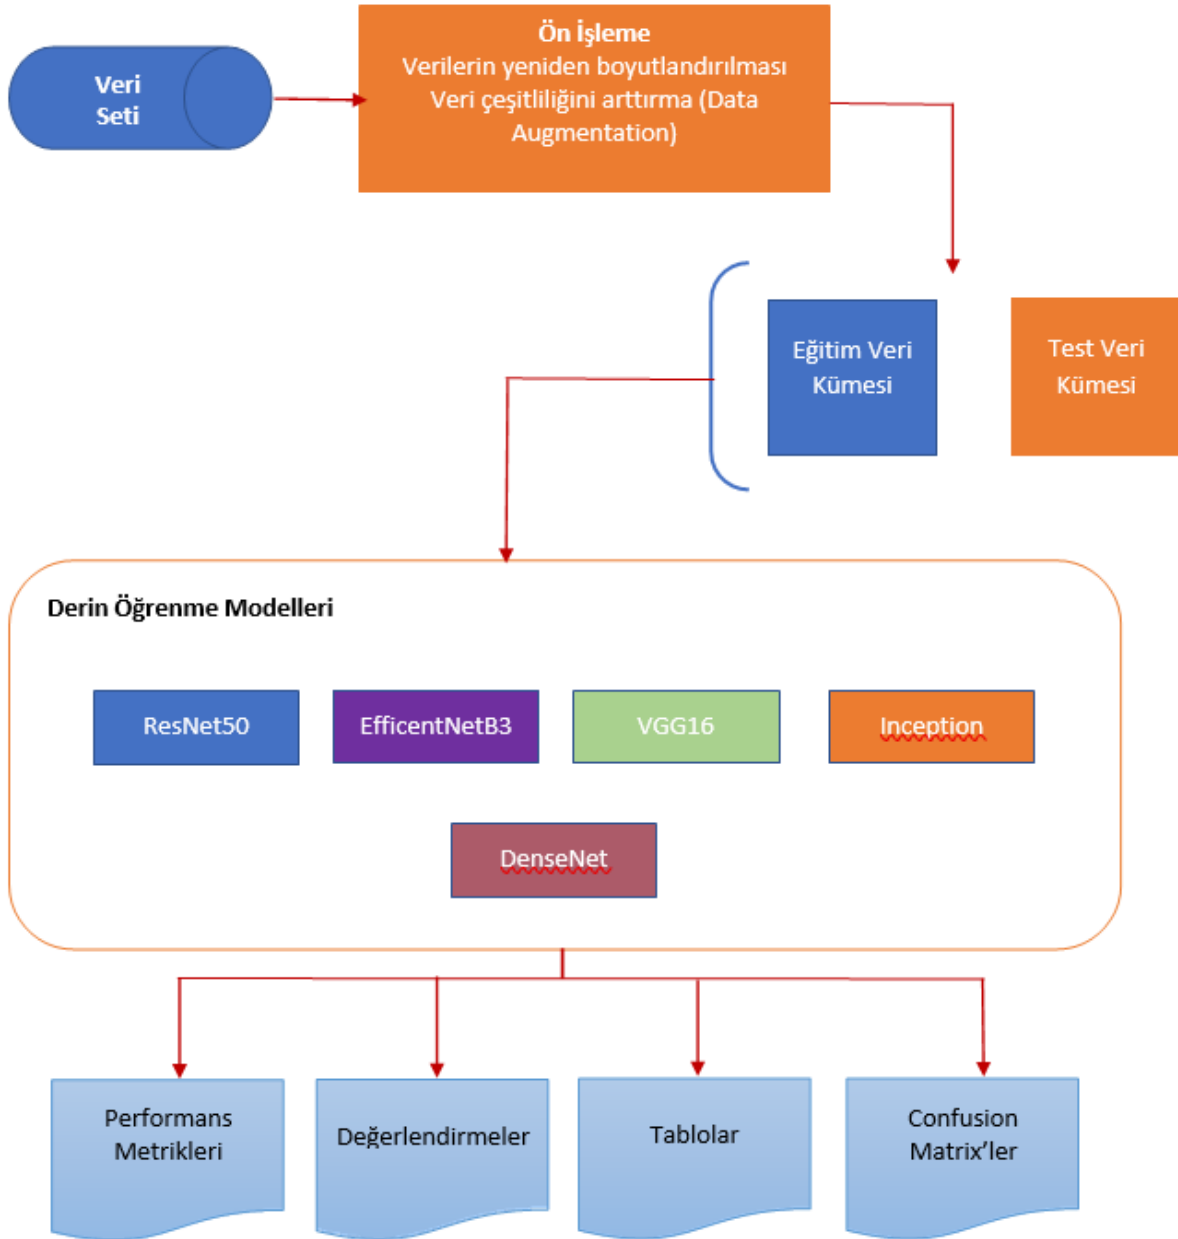
Beyin tümörü sınıflandırması için Yerel İkili Örnekleme (YİÖ), komşuluklara göre YİÖ (dYİÖ) ve açılara dayalı YİÖ ( $\alpha$ YİÖ) tabanlı öznetelik çıkarma yöntemleri kullanılmıştır. Önerilen yöntemlerde kullanılan öznetelikler, Destek Vektör Makineleri (DVM), k-en yakın komşuluk (k-NN), Lojistik Regresyon (LR), Yapay Sinir Ağları (YSA) ve Rastgele Orman (RO) modelleri ile sınıflandırılmıştır. Ayrıca, derin öğrenme modelleri olan Alexnet, VGG19 ve Resnet101 de kullanılmıştır. Test sonuçlarına göre, en yüksek başarı %94,66 olarak VGG19 ve Resnet101 modelleriyle elde edilmiştir [15].

Literatür taramaları incelendiğinde beyin tümörü sınıflandırılmasında makine öğrenimi ve derin öğrenme yöntemlerinin sıklıkla kullanıldığını, oldukça yüksek başarı oranları elde edildiği görülmüştür. Beyin tümörü MRI görüntülerinin sınıflandırılmasında da literatürdeki bazı modeller ve yöntemler kullanılmıştır.

### 3. YÖNTEM

Bu çalışmada, MRI görüntüleri bulunan üç tümör çeşidini ve tümör olmayan beyin MRI görüntülerini, yüksek doğruluk oranlarında birbirinden ayırt etmek ve evrimsel sinir ağı

modelini (CNN-Convolutional Neural Network) eğiterek sınıflandırma yapılmıştır. Çalışmanın genel yapısı Şekil 5'te gösterilmektedir.



Şekil 5. Çalışmanın Sistem Mimarisi

Sistem mimarisinde de görüldüğü üzere veriler yeniden boyutlandırılmış ve veri çeşitliliği artırılmıştır. Ardından eğitim ve test veri seti oluşturulmuş olup derin öğrenme modelleri ile eğitilmiştir. Son olarak sonuçlar tablo veya grafik ile alınmış olup değerlendirilmiştir.

### 3.1. Veri Artırma (Data Augmentation)

Veri büyütme, halihazırda var olan verilerin biraz değiştirilmiş kopyalarını veya mevcut verilerden yeni oluşturulan sentetik verileri ekleyerek veri miktarını artırmak için kullanılan tekniklerdir.

Ön işlem sürecinde mevcutta bulunan eğitim verisi örneklerinin resimler için döndürme, öteleme, kırpmaya, soldurma, ölçeklendirme; sesler için frekans maskeleyme, ölçeklendirme; metinler için eş anlamlısıyla değiştirme, rastgele kelime silme vb. çeşitli teknikler ile işlenmiş sentetik (artificial) kopyalarını oluşturmaktadır ve bu kopyaları mevcut eğitim verisine ekleyerek büyük bir eğitim verisi setini kullanıma hazır hale getirmektedir.

Veri setimiz üzerinde doğruluk oranını artırmak yani veri setini daha iyi eğitmek için bazı veri artırma işlemi kullanılmaktadır. Veri setinde bulunan görüntüleri yatay ve dikey olarak kaydırma, görüntülerin üzerine 0,1 oranında yakınlaşma (zoom) ve görüntüler üzerinde gerçekleştirilecek rastgele rotasyonlar için belli derece aralığında olması sağlanmıştır.

### **3.2. Beyin Tümörü Sınıflandırması için Veri Seti**

Çalışmaya konu olan veri seti, Kaggle üzerinde 2020 yılında yayınlanan üç tümör çeşidinden elde edilen MRI görüntülerini ve tümör bulundurmayan beyin MRI görüntülerini içermektedir. Veri seti toplamda 3264 MRI görüntüsünden oluşmaktadır [16]. Veri setinde bulunan tümör çeşitlerindeki MRI görüntüleri dengeli bir şekilde dağıtılmıştır. Bu sayede modelin daha iyi öğrenmesi amaçlanmıştır.

## **4. UYGULAMA**

### **4.1. Veri Kümesi**

Bu çalışmada glioma, menenjiyom, hipofiz tümörü ve sağlıklı beyin MR görüntülerinin son teknoloji ürünü dört evrişimli sinir ağı (CNN) modeli olan ResNet, EfficientNet, VGG-16 ve Inception modelleri kullanılarak sınıflandırma amaçlanmıştır. Bu çalışmada, bu modellerin her birine ve sınıflandırma görevindeki performanslarına ayrıntılı bir genel bakış sunulmaktadır.

Tıbbi görüntüleme, beyin tümörlerinin tanı ve tedavisinde hayati bir rol oynamaktadır. Manyetik Rezonans Görüntüleme (MRG), beyin tümörü teşhisinde en sık kullanılan görüntüleme yöntemlerinden biridir. Bununla birlikte, özellikle beyin görüntüleme konusunda sınırlı deneyimi olan radyologlar için MRI görüntülerinin yorumlanması zor olmaktadır.

Beyin tümörlerinin tanı ve tedavisine yardımcı olmak için, radyologların MRI görüntülerinden beyin tümörlerini tanımlamasına ve sınıflandırmasına yardımcı olmak için bilgisayar destekli tanı (CAD) sistemleri geliştirilmiştir.

Böyle bir veri kümesi, Kaggle'da bulunan "MRI Verilerini Kullanarak Beyin Tümörü Sınıflandırması" veri kümesidir. Bu veri seti, beyin tümörlerinin MRI görüntülerini ve görüntüde bulunan tümörün türünü (yani, iyi huylu veya kötü huylu bir tümör olup olmadığını) gösteren karşılık gelen etiketleri içermektedir.

Veri seti, iyi huylu tümörlerin 155 görüntüsü ve kötü huylu tümörlerin 98 görüntüsü ile 253 MRI görüntüsünden oluşmaktadır. Bu, veri setindeki görüntülerin %61'inin iyi huylu tümörlere, %39'unun ise kötü huylu tümörlere ait olduğu anlamına gelmektedir. İki sınıf arasındaki bu veri dağılımı, tümörleri doğru bir şekilde sınıflandırma yeteneği açısından sistemin performansını etkileyebileceğinden, bir CAD sistemi geliştirirken dikkate alınması önem arz etmektedir.

Verilerin iki sınıf arasındaki dağılımına ek olarak, verilerin her bir sınıf içindeki dağılımını da dikkate almak önemlidir. Örneğin, iyi huylu tümör görüntülerinin boyut ve şekil olarak daha

geniş varyasyonlar içermesi, kötü huylu tümör görüntülerinin ise özellikleri açısından daha homojen olması mümkündür. Bu, bir CAD sisteminin tümörleri her bir sınıfta doğru bir şekilde sınıflandırma yeteneğini etkilemektedir.

## 4.2. Verilerin Hazırlanması

Beyin tümörü sınıflandırması için bir bilgisayar destekli teşhis (CAD) sistemi geliştirme sürecinde, sistemin tümörleri doğru bir şekilde sınıflandırabilmesini sağlamak için verileri uygun şekilde önceden işlemek önemlidir. Verilerin ön işlenmesindeki ilk adım, görüntüleri 150x150 piksel olarak yeniden boyutlandırmaktır. Bu, CAD sisteminin performansına yardımcı olabilecek tüm görüntülerin tutarlı bir boyutta olmasını sağlamak için yapılmıştır.

Ardından, verilerin çeşitliliğini artırmak için görüntüler üzerinde %0 ile %7 arasındarastgele döndürmeler yapılmıştır. Bu, CAD sisteminin veri kümesindeki görüntülerin belirliyönüne aşırı uymasını önlemeye yardımcı olabilmektedir ve modelin sağlamlığını artırmaktadır. Rastgele döndürmelere ek olarak, görüntüler yatay ve dikey olarak döndürülmüştür. Bu, verilerin çeşitliliğini daha da artırmak ve CAD sisteminin, görüntünün yönü ne olursa olsun tümörleri doğru bir şekilde sınıflandırabilmesini sağlamak için yapılmıştır. Bu ön işleme adımlarının gerçekleştirilmesiyle veriler, CAD sisteminin performansını iyileştirebilecek daha tutarlı ve çeşitli bir kümeye dönüştürülmüştür.

Modelin adil bir şekilde değerlendirilmesi için ön işleme adımının eğitim sürecinden önce yapılması ve test veri setinin aynı olması gerektiğine dikkat etmek önem arz etmektedir. Sonuç olarak, beyin tümörü sınıflandırması için bir CAD sistemi geliştirmede verilerin ön işlenmesi önemli bir adımdır. Görüntüleri tutarlı bir boyuta yeniden boyutlandırarak, rastgele döndürmeler gerçekleştirerek ve görüntüleri yatay ve dikey olarak döndürerek, veriler CAD sisteminin performansını iyileştirebilecek daha tutarlı ve çeşitli bir kümeye dönüştüreceklerdir.

## 4.3. Kullanılan Modeller

### 4.3.1. ResNet50

ResNet50, derin bir artık sinir ağı olan ResNet mimarisinin bir varyasyonudur. ResNet'in arkasındaki ana fikir, atlama bağlantıları olarak da bilinen kısayol bağlantılarını tanıtarak derin sinir ağlarında yok olan gradyan sorununu hafifletmektir. Bu bağlantılar, ağına girdiyi ara katmanları atlayarak daha derin bir katmana doğrudan iletmesine izin vermektedir [17].

Bu, kısayol bağlantıları girdiden gelen bilgilerin korunmasına yardımcı olduğundan, fazla takma riski olmadan çok daha derin ağları eğitmeyi mümkün kılmaktadır. Orijinal ResNet mimarisi 50 katman kullanmaktaydı, ancak daha da fazla katman kullanan ResNet-101, ResNet-152 ve ResNet-200 gibi sonraki sürümler önerilmiştir.

ResNet50 modeli 50 katmanlı bir artık ağıdır ve daha derin ve daha güçlü modellerden biri olarak kabul edilmektedir. ImageNet veri kümesi üzerinde eğitilmiştir ve milyonlarca görüntü ve binlerce sınıf üzerinde önceden eğitilmiştir, bu da onu görüntü sınıflandırma görevleri için çok güçlü bir model haline getirmektedir [18].

ResNet50, görüntü sınıflandırması için en doğru modellerden biri olarak kabul edilmektedir ve nesne algılama, anlamsal bölümlendirme ve görüntü alt yazılama gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır. ResNet50'nin mimarisi, artık blok olarak adlandırılan ResNet'in yapı

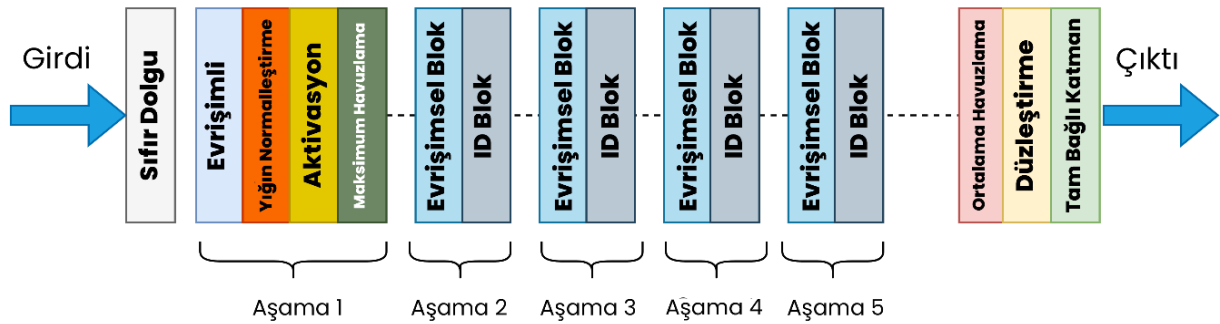


taşına dayanmaktadır. Artık bir blok, aralarında toplu normalleştirme ve ReLU aktivasyonu olan iki veya daha fazla evrişimli katmandan oluşmaktadır. Artık bloğun ayrıca, girişin ara katmanları atlmasına ve doğrudan çıkışa geçmesine izin veren bir kısayol bağlantısı bulunmaktadır.

Bu, kısayol bağlantıları girdiden gelen bilgilerin korunmasına yardımcı olduğundan, fazla takma riski olmadan çok daha derin ağları eğitmeyi mümkün kılmaktadır. ResNet50, görüntülerdeki karmaşık kalıpları yakalamasına izin veren çok sayıda parametreye sahiptir. Bu, sağlıklı ve hastalıklı bir görüntü arasındaki farkın ince olabildiği tıbbi görüntü analizi gibi yüksek düzeyde doğruluk gerektiren görüntü sınıflandırma görevleri için uygun hale getirmektedir.

ResNet50, beyin MRG'lerinde tümörlerin saptanması, histopatoloji görüntülerinde kanserli hücrelerin belirlenmesi ve BT taramalarında akciğer kanserinin saptanması gibi çeşitli tıbbi görüntü analizi görevlerinde kullanılmıştır. Sonuç olarak ResNet50, nesne algılama, semantik bölümlendirme ve görüntü altyazı oluşturma gibi çeşitli uygulamalarda yaygın olarak kullanılan, görüntü sınıflandırma için güçlü ve doğru bir modeldir.

Görüntülerdeki karmaşık kalıpları yakalama yeteneği, onu tıbbi görüntü analizi gibi yüksek düzeyde doğruluk gerektiren görüntü sınıflandırma görevleri için uygun hale getirmektedir. Şekil 6'da görüldüğü üzere, ResNet50'nin rezidüel bloğa dayalı mimarisi, diğer modellere göre büyük bir avantaj olan aşırı uyum riski olmadan çok daha derin ağları eğitmesine olanak tanımaktadır.



Şekil 6. Resnet50 modeli mimarisi [19]

#### 4.3.2. EfficientNet-B3

EfficientNet-B3, Google AI araştırmacıları tarafından geliştirilen son teknoloji evrişimli sinir ağı (CNN) modelidir. Model, hesaplama kaynaklarının daha verimli kullanımıyla yüksek doğruluk elde etmek için tasarlanmış EfficientNet model ailesinin bir parçasıdır. EfficientNet-B3, toplam 528 milyon parametre ile EfficientNet ailesinin üçüncü ve en büyük modelidir [20].

EfficientNet modellerinin temel yeniliği, daha küçük modellerle benzer bir hesaplama maliyetini korurken, modelin kapasitesini artırmasına izin veren bileşik bir ölçeklendirme yönteminin kullanılmasıdır. Bu, modelin çözünürlüğünü, derinliğini ve genişliğini koordineli bir şekilde ölçeklendirerek elde edilmektedir. EfficientNet-B3, daha küçük EfficientNet-B0 modeliyle aynı mimariyi temel alır, ancak daha büyük giriş çözünürlüğüne (320x320) ve evrişimli katmanlarda daha fazla filtreye sahiptir.

EfficientNet-B3'ün ana avantajlarından biri, çok çeşitli görüntü sınıflandırma görevlerinde yüksek doğruluğudur. Model, ImageNet veri setinde önceden eğitilmiştir ve nispeten az sayıda etiketli örnekle diğer veri setlerinde ince ayar yapılabilir. Modelin ayrıca COCO veri setinde ince ayar yapıldığında nesne algılama ve semantik bölümlenme görevlerinde iyi performans gösterdiği gösterilmiştir.

EfficientNet-B3'ün diğer bir avantajı, hesaplama maliyeti açısından verimliliğidir. Model, benzer sayıda parametreye sahip, ancak önemli ölçüde daha iyi doğrulukla diğer modellerle benzer bir hesaplama maliyetine sahiptir. Bu, EfficientNet-B3'ü mobil cihazlar veya uç cihazlar gibi bilgi işlem kaynaklarının sınırlı olduğu uygulamalar için iyi bir seçim haline getirir. EfficientNet-B3, görüntü sınıflandırma, nesne algılama, semantik bölümlenme ve çok daha fazlasını içeren çok çeşitli uygulamalarda kullanılabilir. Model, belirli bir görev için yüksek doğruluk elde etmek üzere belirli bir veri kümesi üzerinde ince ayar yapılabilir veya diğer modeller için bir özellik çıkarıcı olarak kullanılabilir [21].

Özetle, EfficientNet-B3, hesaplama kaynaklarının daha verimli kullanımıyla yüksek doğruluk elde etmek için tasarlanmış, Google AI araştırmacıları tarafından geliştirilmiş, son teknoloji ürünü bir evrişimli sinir ağı modelidir. Daha küçük EfficientNet-B0 modeliyle de aynı mimariye dayalıdır, ancak daha büyük giriş çözünürlüğü ve evrişimli katmanlarda daha fazla filtre içermektedir. ImageNet veri kümesi üzerinde önceden eğitildiğinden ve çok çeşitli görüntü sınıflandırma, nesne algılama ve semantik bölümlenme görevlerinde iyi performans gösterdiği gösterilmiştir. Ek olarak, hesaplama maliyeti açısından verimlidir ve hesaplama kaynaklarının sınırlı olduğu uygulamalar için iyi bir seçimidir.

#### 4.3.3. VGG-16

VGG-16, Oxford Üniversitesi'nde Visual Geometry Group (VGG) tarafından 2014 yılında tanıtılan evrişimli bir sinir ağı mimarisidir. Mimari, basitliği ve görüntü sınıflandırma görevlerinde yüksek doğruluk elde etme yeteneği ile bilinir. VGG-16 modeli, 13 evrişimli katmandan ve 3 tam bağlantılı katmandan oluşan 16 katmanlı bir ağıdır [22].

ImageNet veri kümesi üzerinde eğitilmiştir ve milyonlarca görüntü ve binlerce sınıf üzerinde önceden eğitilmiştir, bu da onu görüntü sınıflandırma görevleri için çok güçlü bir model haline getirmektedir. VGG-16'nın mimarisi, tekdüze bir evrişimli katman yapısı, toplu normalleştirme ve ReLU aktivasyonu ile nispeten basittir. Evrişimli katmanlar, her grup 2 veya 3 evrişimli katman içeren gruplar halinde düzenlenir. Ağda daha derine inildikçe her evrişim katmanındaki filtre sayısı artar. Bu, modelin ağı derinliklerine indikçe daha karmaşık özellikleri yakalamasını sağlamaktadır. VGG-16 mimarisi, modelin görüntülerde ince taneli ayrıntıları yakalamasına olanak tanıyan 3x3 boyutunda küçük evrişimli filtreler kullanması ile bilinmektedir. Model ayrıca her evrişim katmanında çok sayıda filtre kullanır ve bu da görüntülerden daha fazla özellik çıkarmasını sağlamaktadır.

Ayrıca VGG-16 modeli, daha karmaşık özellikleri öğrenmesine olanak tanıyan çok derin mimarilerle eğitilmiştir. VGG-16'nın ana avantajlarından biri, nispeten basit bir mimari ile görüntü sınıflandırma görevlerinde yüksek doğruluk elde edebilmesidir. Bu, onu nesne algılama, semantik bölümlenme ve görüntü alt yazısı gibi çeşitli uygulamalar için popüler bir model yapmaktadır. Bununla birlikte, VGG-16'nın ana dezavantajlarından biri, onu eğitmeyi ve kullanmayı hesaplama açısından pahalı hale getiren çok sayıda parametredir. Bu, gerçek zamanlı işlem gerektiren görevler veya sınırlı bilgi işlem kaynaklarına sahip cihazlar için bir sorun olabilmektedir.

Sonuç olarak, VGG-16, görüntü sınıflandırma görevleri için güçlü ve yaygın olarak kullanılan bir modeldir. Basit mimarisi ve görüntü sınıflandırma görevlerinde yüksek doğruluk elde etme yeteneği, onu nesne algılama, semantik bölümlenme ve görüntü alt yazısı gibi çeşitli uygulamalar için popüler bir model haline getirmektedir. Bununla birlikte, çok sayıda parametresi, onu eğitmeyi ve kullanmayı hesaplama açısından pahalı hale getirir; bu, gerçek zamanlı işleme gerektiren görevler veya sınırlı hesaplama kaynaklarına sahip cihazlar için bir sorun olabilmektedir.


#### 4.3.4. Inception-V3

Inception modeli, Google tarafından 2014 yılında kullanıma sunulan evrişimli bir sinirağı mimarisidir. Mimari, hesaplama açısından verimli olurken görüntü sınıflandırma görevlerinde yüksek doğruluk elde etme becerisiyle bilinmektedir. Inception modeli, mimariyi oluşturmak için kullanılan yapı taşları olan Inception modülleri konsepti üzerine inşa edilmiştir. Bu modüller, evrişim, havuzlama ve normalleştirme katmanlarının bir kombinasyonunu kullanarak girdi görüntüsünden birden fazla ölçekte öznelikler çıkarmak için tasarlanmıştır [23].

Inception modeli, giriş görüntüsünden özellikleri çıkarmak için 1x1 evrişim, 3x3 evrişim ve 5x5 evrişim gibi farklı evrişim katmanlarının bir kombinasyonunu kullanmaktadır. 1x1 evrişim, özellik haritalarının sayısını azaltmak için kullanılırken, 3x3 ve 5x5 evrişim dahakarmaşık özellikleri çıkarmak için kullanılmaktadır. Ek olarak Başlangıç modeli, özellikleri birden çok ölçekte ayıklamak için maksimum havuzlama ve ortalama havuzlamanın bir kombinasyonunu kullanır.

Inception modelinin ana avantajlarından biri, modelin giriş görüntüsündeki daha karmaşık özellikleri yakalamasına izin veren birden fazla ölçekte öznelikleri çıkarabilme yeteneğidir. Bu, modeli giriş görüntüsündeki değişikliklere karşı daha dayanıklı hale getirmekte ve yeni verilere genelleştirme yeteneğini geliştirmektedir. Ek olarak, Inception modeli hesaplama açısından verimlidir ve bu da onu gerçek zamanlı işleme gerektiren görevler veya sınırlı hesaplama kaynaklarına sahip cihazlar için uygun kılmaktadır.

Inception modeli, nesne algılama, semantik bölümlenme ve görüntü alt yazısı oluşturma gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır. Bununla birlikte, Başlangıç modelinin ana dezavantajlarından biri, onu eğitmeyi ve kullanmayı hesaplama açısından pahalı hale getiren çok sayıda parametredir. Bu, gerçek zamanlı işlem gerektiren görevler veya sınırlı bilgi işlem kaynaklarına sahip cihazlar için bir sorun olabilmektedir. Şekil 7'de örnek bir Inception model katman yapısı gösterilmiştir.



Şekil 7. Inception modeli katman yapısı [24]

#### 4.3.5. DenseNet

DenseNet, 2016 yılında Gao Huang ve diğerleri tarafından "Yoğun Bağlantılı Evrişimli Ağlar" makalesinde tanıtılan bir derin öğrenme modelidir. Bu model, her katmanın diğer tüm katmanlara ileri beslemeli bir şekilde bağlandığı katmanlar arasındaki bağlantılara atıfta bulunan yoğun bağlantıların kullanımıyla bilinmektedir. Bu, her katmanın önceki katmanlardan yalnızca birkaçına bağlı olduğu geleneksel evrişimli sinir ağlarından (CNN'ler) farklıdır [25].

DenseNet mimarisi, her bloğun birden çok katman içerdiği birden çok yoğun blokta oluşmaktadır. Yoğun bir blok içindeki her katman, bloktaki önceki tüm katmanlardan girdi olarak daha verimli bir bilgi akışı sağlamaktadır. Bu yapı, kaynakların daha verimli kullanılmasını sağlamakta ve modeli eğitmek için gereken parametre sayısını azaltmaktadır.

DenseNet'in avantajlarından biri, eğitim sırasında ağ üzerinden geri aktıkça gradyanların çok küçük hale geldiği derin öğrenmede yaygın bir sorun olan kaybolan gradyan sorununa daha az eğilimli olmasıdır. Bu, daha derin ağları eğitmeyi kolaylaştırır ve daha iyi performansla sonuçlanmaktadır. DenseNet ayrıca, özellik haritalarının ağ üzerinden akarken boyutsallığını azaltmak için kullanılan, geçiş katmanları olarak bilinen bir özelliğe de sahiptir. Bu katmanlar, yoğun bloklar arasına yerleştirilir ve özellik haritalarındaki kanal sayısını azaltmak için kullanılır, böylece modelin hesaplama maliyeti azalır.

Özetle, DenseNet, katmanlar arasında yoğun bağlantılar kullanan, daha verimli bir bilgi akışı sağlayan ve modeli eğitmek için gereken parametre sayısını azaltan bir derin öğrenme modelidir. Mimarisi, daha iyi performans sağlar ve kaybolan gradyan problemine daha az eğilimlidir ve geçiş katmanları, modelin hesaplama maliyetini azaltmak için kullanılmaktadır.

### 5. DERİN ÖĞRENME PERFORMANS METRİKLERİ

Derin öğrenmede, bir modelin sonuçlarını değerlendirmek ve etkinliğini belirlemek için model performans ölçümleri kullanılmaktadır. Bir modelin performansını değerlendirmek için sık kullanılan ölçütler doğruluk, kesinlik, duyarlılık, F1 skorudur [26].

- Doğruluk (Accuracy): Bu, bir modelin performansını değerlendirmek için kullanılan en yaygın ölçümdür. Şekil 8 denklem 1'de görüldüğü gibi model tarafından yapılan doğru tahmin sayısının yapılan toplam tahmin sayısına oranıdır. Doğruluk metriği genellikle veri kümesindeki sınıflar dengelendiğinde kullanılır, yani her sınıf için kabaca aynı sayıda örnek vardır.
- Kesinlik (Precision): Kesinlik, şekil 8 denklem 2'de görüldüğü üzere model tarafından yapılan gerçek pozitif tahminlerin tüm pozitif tahminler içindeki oranını ölçen bir metriktir. Modelin yanlış pozitiflerden kaçınma yeteneğinin bir ölçüsüdür. Yüksek hassasiyet, modelin düşük yanlış pozitif oranına sahip olduğu anlamına gelmektedir.
- Duyarlılık (Recall): Hatırlama, şekil 8 denklem 3'te görüldüğü gibi model tarafından yapılan gerçek pozitif tahminlerin tüm gerçek pozitif vakalar içindeki oranını ölçen bir ölçümdür. Modelin pozitif vakaları tespit etme yeteneğinin bir ölçüsüdür. Yüksek hatırlama, modelin düşük yanlış negatif oranına sahip olduğu anlamına gelmektedir.
- F1 Skoru (F1-score): F1 skoru, kesinlik ve hatırlamayı birleştiren bir modelin doğruluğunun ölçüsüdür. Şekil 8 denklem 4'te görüldüğü üzere Kesinlik ve

hatırlamanın harmonik ortalamasıdır. F1 skoru, özellikle veri kümesindeki sınıflar dengesiz olduğunda kullanışlıdır.

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

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

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{F1-Skor (F1-Score)} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

Şekil 8. Model performans metrik formülleri

Beyin tümörü MR veri kümesi bağlamında, doğruluk, kesinlik, hatırlama, F1 puanı modellerin sonuçlarını ve ayrıca modelin farklı tümör türlerini doğru bir şekilde sınıflandırmabecerisini değerlendirmek için en alakalı ölçütler olarak görülmektedir.

## 6. BULGULAR

### 6.1. Doğruluk Oranlarının Değerlendirilmesi

Modellerin sonuçlarına ve tablo 1'deki oranlara göre ResNet modeli, karşılaştırılan beş model arasında %98 ile en yüksek doğruluk oranına sahiptir. Bunu %96 doğruluk oranıyla EfficientNet modeli takip ederken, VGG16, Inception V3 ve DenseNet modelleri sırasıyla %91, %92 ve %88 doğruluk oranlarına sahiptir.

Bu sonuçlara dayanarak, ResNet modelinin doğruluk açısından karşılaştırılan beş model arasında en iyi performansı gösterdiği sonucuna varılabilmektedir. Bununla birlikte, bir modelin performansını değerlendirirken dikkate alınması gereken tek metrik doğruluğun her zaman olmadığını ve hesaplama maliyeti ve hız gibi diğer faktörlerin de dikkate alınması gerektiğini not etmek önemlidir. Ek olarak, bu tablodaki sonuçlar kullanılan veri kümesine ve problem türüne özgü olabilir, bu nedenle genelleme yeteneklerini değerlendirmek için modelleri farklı veri kümeleri ve problem türleri üzerinde test etmek her zaman daha iyidir.

Tablo1. Modellerin Doğruluk oranları

EfficientNet B3	ResNet50	VGG16	Inception V3	DenseNet
% 96	% 98	% 91	% 92	% 88

### 6.2. Kesinlik Oranlarının Değerlendirilmesi

Tablo 2, bir beyin tümörleri veri kümesinde beş farklı modelin (EfficientNet, ResNet, VGG16, Inception V3 ve DenseNet) kesinlik oranlarını göstermektedir. Modeller dört farklı tümör tipi üzerinde değerlendirilmektedir: "Tümör Yok", "Hipofiz Tümörü", "Meningioma Tümörü" ve "Glioma Tümörü".

Tablo 2'ye göre, EfficientNet ve ResNet modelleri en yüksek genel kesinlik oranlarına sahiptirler; EfficientNet en iyi performansı "Tümör Yok" ve "Hipofiz Tümörü" sınıflarında ve ResNet en iyi performansı "Meningioma Tümörü" ve "Glioma Tümörü" sınıflarında göstermektedir. VGG16, Inception V3 ve DenseNet modelleri, karşılaştırıldığında daha düşük bir doğruluğa sahiptirler, ancak belirli sınıflarda da iyi performans göstermektedirler.

EfficientNet ve ResNet modellerinin veri seti üzerinde genel olarak en iyi performansa sahip olduğu sonucuna varılmıştır, ancak farklı sınıflar açısından farklı güçlere sahip olduklarını belirtmekte fayda vardır. VGG16, Inception V3 ve DenseNet modelleri de belirli sınıflarda iyi performans göstermekte ve belirli tümör türleri için bunları dikkate almaya değerdir.

**Tablo 2.** Modellerin Kesinlik Oranları

Sınıf	EfficientNetB3	ResNet50	VGG16	Inception V3	DenseNet
Tümör Yok	%94	%99	%85	%97	%89
Hipofiz Tümör	%94	%96	%90	%85	%79
Meningioma Tümör	%96	%94	%97	%92	%90
Glioma Tümör	%100	%100	%94	%95	%96

### 6.3. Duyarlılık Oranlarının Değerlendirilmesi

Tablo 3, bir beyin tümörleri veri kümesi üzerinde beş farklı modelin (EfficientNet, ResNet50, VGG16, Inception V3 ve DenseNet) duyarlılık oranlarını göstermektedir. Modeller dört farklı tümör tipi üzerinde değerlendirilmektedir: "Tümör Yok", "Hipofiz Tümörü", "Meningioma Tümörü" ve "Glioma Tümörü". Tablo 3'e göre ResNet modeli, "Tümör Yok" ve "Glioma Tümör" sınıflarında en yüksek duyarlılık oranları ile en yüksek genel duyarlılık oranına sahiptir. EfficientNet, VGG16, Inception V3 ve DenseNet modelleri de belirli sınıflarda yüksek hassasiyet oranına sahiptir ancak ResNet50'ye göre daha düşük oranlara sahiptir.

**Tablo 3.** Modellerin duyarlılık oranları

Sınıf	EfficientNet	ResNet	VGG16	Inception V3	DenseNet
Tümör Yok	%94	%95	%90	%84	%82
Hipofiz Tümör	%95	%97	%82	%94	%85
Meningioma Tümör	%99	%99	%96	%91	%93
Glioma Tümör	%99	%100	%97	%98	%95

ResNet modelinin, veri kümesi üzerinde en iyi genel duyarlılık performansına sahip olduğu sonucuna varılmıştır. Ancak EfficientNet, VGG16, Inception V3 ve DenseNet modelleri de belirli sınıflarda yüksek hassasiyet oranlarına sahiptir ve belirli tümör türleri için dikkate alınmalıdır.

Modeller, genelleme yeteneklerini değerlendirmek için farklı veri kümeleri ve problem türleri üzerinde test edilmelidir. Ek olarak, bir modelin performansını değerlendirirken dikkate alınması gereken tek ölçüm her zaman kesinlik değildir ve hesaplama maliyeti ve hız gibi diğer faktörler de dikkate alınmalıdır.

Bu sonuçların bu çalışmada kullanılan veri kümesine ve soruna özel olduğunu akılda tutmak önemlidir. Modeller, genelleme yeteneklerini değerlendirmek için farklı veri kümeleri ve problem türleri üzerinde test edilmelidir. Ek olarak, bir modelin performansını değerlendirirken

dikkate alınması gereken tek ölçüm her zaman hassasiyet değildir ve özgünlük ve doğruluk gibi diğer faktörler de dikkate alınmalıdır.

Sonuç olarak, ResNet modeli beyin tümörlerinin bu veri kümesinde en iyi genel hassasiyet performansına sahiptir, ancak EfficientNet, VGG16, Inception V3 ve DenseNet modelleri de belirli sınıflarda yüksek hassasiyet oranlarına sahiptir. Bu sonuçları belirli bir sorun ve veri kümesi bağlamında değerlendirmek ve diğer ölçütleri kullanarak modelleri değerlendirmek önemlidir.

#### 6.4. F1-Skor Oranlarının Değerlendirilmesi

Tablo 4, dört farklı tümör türü (Tümör Yok, Hipofiz Tümörü, Meningioma Tümörü ve Glioma Tümörü) için beş farklı modelin (EfficientNet, ResNet, VGG16, Inception V3, DenseNet) f1-skorunu göstermektedir. Tablo 4'e göre modellerin her bir tümör tipi için farklı performans sonuçlarına sahip olduğu görülmektedir.

EfficientNet modelinin f1 skoru Tümör Yok için %94, Hipofiz Tümörü için %95, Meningioma Tümörü için %97 ve Glioma Tümörü için %99'dur. Benzer şekilde, ResNet modelinin f1 skoru Tümör Yok için %97, Hipofiz Tümörü için %97, Meningioma Tümörü için %96 ve Glioma Tümörü için %100'dür.

Genel olarak, tüm modellerin Glioma Tümörü için yüksek f1 skorlarına sahip olduğu, buna karşın Hipofiz Tümörü için skorların nispeten daha düşük olduğu görülebilmektedir. Ancak, bu sonuçların sınırlı bir örneklem büyüklüğüne dayandığı ve daha geniş bir popülasyona genellenemeyeceğini belirtilmek gerekir. Bu modellerin farklı tümör tiplerini tespit etmedeki performansı hakkında daha sağlam sonuçlar çıkarmak için daha büyük bir veri kümesiyle daha fazla araştırmaya ihtiyaç vardır.

**Tablo 4.** Modellerin F1 Skor Oranları

Sınıf	EfficientNetB03	ResNet50	VGG16	Inception V3	DenseNet
<b>Tümör Yok</b>	%94	%97	%87	%90	%85
<b>Hipofiz Tümör</b>	%95	%97	%86	%90	%82
<b>Meningioma Tümör</b>	%97	%96	%97	%91	%92
<b>Glioma Tümör</b>	%99	%100	%95	%96	%96

#### 6.5. Modellerin Sınıflara Göre Yaptığı Tahmin Sayılarının Değerlendirilmesi

Tablo 5 EfficientNet, ResNet, VGG16, Inception V3 ve DenseNet modellerinin Tümör Yok, Hipofiz Tümörü, Meningioma Tümörü ve Glioma Tümörü sınıflarına göre yaptığı doğru tahmin sayısını göstermektedir. Bu sonuçlara göre, EfficientNet modelinin Tümör Yok ve Hipofiz Tümörünü doğru bir şekilde tanımlamada, ResNet modeli ise Meningioma Tümörünü doğru bir şekilde tanımlamada iyi performans gösterdiği görülmektedir. Ancak, tüm modeller Glioma Tümörünü doğru bir şekilde tanımlamada nispeten daha az performans göstermiştir. Genel olarak, tüm modellerin sınıf örneklerinin çoğunluğunu doğru bir şekilde tanımlamada iyi performans gösterdiği sonucuna varılmıştır, ancak Glioma Tümörünü doğru bir şekilde tanımlamada iyileştirme için yer vardır.

**Tablo 5.** Modellerin sınıflara göre doğru tahmin sayıları

Sınıf	EfficientNetB03	ResNet50	VGG16	Inception V3	DenseNet
Tümör Yok	77	79	74	74	78
Hipofiz Tümör	133	135	140	139	133
Meningioma Tümör	142	142	129	156	151
Glioma Tümör	138	134	147	121	128


### 6.6. EfficientNetB3 Modelinin Performans Ölçümü

Tablo 6'daki performans tablosuna dayalı olarak, EfficientNet modeli, beyin tümörü tiplerinin sınıflandırılmasında güçlü sonuçlar göstermiştir. Model, "Tümör Yok" sınıfı için %94'ün üzerinde kesinlik, duyarlılık ve f1 skoru ile %96'lık bir doğruluk elde edilmiştir. Ek olarak model, Pituitary Tümörü, Meningioma Tümörü ve Glioma Tümörü için sırasıyla %95, %97 ve %99'luk f1 skorları ile diğer tümör tiplerini sınıflandırmada iyi performans göstermektedir. Genel makro ortalama ve ağırlıklı ortalama f1 puanları da %96 idi ve bu, tüm sınıflarda tutarlı performansa işaret etmektedir. Şekil 9'daki confusion matrix'te incelendiğinde, bu sonuçlar, EfficientNet modelinin beyin tümörü tiplerini sınıflandırmada oldukça etkili olduğu görülmektedir.

**Tablo 6.** EfficientNetB3 Model Performans Tablosu

	Kesinlik	Duyarlılık	F1-Score	Gerçek Sayısı	Örneklerin
Tümör Yok	%94	%94	%94	139	
Hipofiz Tümör	%94	%95	%95	141	
Meningioma Tümör	%96	%99	%97	75	
Glioma Tümör	%100	%99	%99	135	
<b>Doğruluk</b>			%96	490	
<b>Makro Ortalama</b>	%96	%96	%96	490	
<b>Ağırlıklı Ortalama</b>	%96	%96	%96	490	






Şekil 9. EfficientNetB3 Confusion Matrix

### 6.7. ResNet50 Modelinin Performans Ölçümü

Aşağıdaki tablo 7, bir ResNet modelinin beyin tümörü tiplerini sınıflandırmadaki performansını göstermektedir. Model, "Tümör Yok" sınıfı için %98'lik bir genel doğruluk ve kesinlik, duyarlılık ve f1 skorunun tümü %94'ün üzerinde elde etmiştir. Model ayrıca Pituitary Tümörü, Meningioma Tümörü ve Glioma Tümörü için sırasıyla %97, %96 ve %100 f1 skorları ile diğer tümör tiplerini sınıflandırmada da iyi performans göstermiştir. Genel makro ortalama ve ağırlıklı ortalama f1 puanları da sırasıyla 0,97 ve 0,98 idi ve bu da tüm sınıflarda tutarlı performansa işaret etmektedir. Şekil 10'daki confusion matrix'te tahmin edilen sınıf sayısına da bakıldığında ResNet modelinin glioma tümör sınıfı için mükemmel yakın performansla beyin tümörü tiplerini sınıflandırmada oldukça etkili olduğunu ve tıbbi görüntüleme analizi için değerli bir araç sağlayabileceğini göstermektedir.


Tablo 7. ResNet50 Model Performans Tablosu

	Kesinlik	Duyarlılık	F1-Score	Gerçek Sayısı	Örneklerin
<b>Tümör Yok</b>	% 99	% 95	% 97	139	
<b>Hipofiz Tümör</b>	% 96	% 97	% 97	141	
<b>Meningioma Tümör</b>	% 94	% 99	% 96	75	
<b>Glioma Tümör</b>	% 100	% 100	% 100	135	
<b>Doğruluk</b>			% 98	490	
<b>Makro Ortalama</b>	% 97	% 98	% 97	490	
<b>Ağırlıklı Ortalama</b>	% 98	% 98	% 98	490	




Şekil 10. ResNet50 Confusion Matrix

Sonuç olarak, dört farklı sınıf içeren bir beyin tümörü MR görüntü veri kümesi üzerinde beş son teknoloji derin öğrenme modelini eğitilmiştir ve değerlendirilmiştir: 'Tümör Yok', 'Hipofiz Tümörü', 'Meningioma Tümörü' ve 'Glioma Tümörü'. Sonuçlarımız, çoğu modelin %90'ın üzerinde doğruluk oranlarına ulaşarak iyi performans göstermektedir. Ancak daha detaylı inceleme yapıldığında EfficientNet ve ResNet modellerinin özellikle 'Tümör Yok' ve 'Glioma Tümörü' sınıflarında en yüksek performansı gösterdiği görülmektedir. Dolayısıyla bu modeller, bu özel uygulama için en uygun modeller olarak kabul edilmektedir. Genel olarak, bu çalışma, beyin tümörü MR görüntüleme farklı derin öğrenme modellerinin performansına ilişkin değerli bilgiler sağlamaktadır ve bu alanda gelecekteki araştırmalara bilgi verecektir.



Şekil 11. 80 eğitim veri seti görüntüsü ve kendilerinin tahmin edilen sınıfı EfficientNetB3



Şekil 12. 80 test veri seti görüntüsü ve kendilerinin tahmin edilen sınıfı ResNet50

## 7. SONUÇ

Bu çalışmada, beyin tümörü olan hastalardan alınan MR görüntülerinden oluşan bir veri kümesi üzerinde farklı derin öğrenme modellerinin performansının değerlendirilmesi amaçlanmıştır. Veri seti dört sınıftan oluşmaktadır: 'Tümör Yok', 'Hipofiz Tümörü', 'Meningioma Tümörü' ve 'Glioma Tümörü'. Veri setini beş farklı model kullanarak eğitilmiştir: EfficientNet, ResNet, VGG16, Inception V3 ve DenseNet. Bu modellerin performansı test edilmiştir ve sonuçlar görselleştirilerek ve analiz edilmiştir.

Analiz sonuçlarına göre EfficientNet %96, ResNet %98, VGG16 %91, DenseNet %88 doğruluk oranlarını vermiştir ve EfficientNet ile ResNet modellerinin en iyi sonuçlar veren modeller olduğu tespit edilmiştir. Bu modellerin özellikle 'Tümör Yok', 'Glioma Tümör' sınıfları için EfficientNet'te, tümör yok sınıfı için %94 oranla f1-skor, %94 oranla kesinlik, %94 oranla duyarlılık, glioma tümör için %99 oranla f1-skor, %100 oranla kesinlik, %99 oranla duyarlılık göstermiş olmakla beraber ResNet'te ise tümör yok sınıfı için %97 oranla f1-skor, %99 oranla kesinlik, %95 oranla duyarlılık glioma tümör için %100 oranla f1-skor, %100 oranla kesinlik, %100 oranla duyarlılık verdiği gözlemlenmiştir.

Aynı veri seti kullanılan başka bir çalışmada VGG-19 modeli kullanılmış ve %95 doğruluk elde edilmiştir. Bu çalışmada ise birçok derin öğrenme modeli kullanılmış olup %98 gibi yüksek bir doğruluk oranı elde edilmiştir. Bu da çalışmada doğru modeller ve uygulamalar yapıldığının bir göstergesidir.

Oranlara ve şekil 11 ile şekil 12'deki görsellere bakıldığında EfficientNet ve ResNet modellerinin özellikle 'Tümör Yok' ve 'Glioma Tümör' sınıflarında en yüksek performansı gösterdiği görülmektedir. Bu nedenle, bu modeller bu özel uygulama için en uygun modeller olarak kabul edilmektedir. Genel olarak derin öğrenme modellerinin beyin tümörlerini MR görüntülerinden sınıflandırmada umut verici sonuçlar gösterdiğini göstermektedir.

Bu çalışma, derin öğrenme modellerinin beyin tümörlerinin sınıflandırılmasında etkili bir araç olduğunu göstermektedir. Elde edilen sonuçlar, bu yöntemin gelecekteki potansiyelini vurgulamaktadır. Derin öğrenme modellerinin kullanılmasıyla, beyin tümörlerinin doğru sınıflandırılması ve teşhisi için yüksek hassasiyet ve doğruluk elde edilmiştir. Bu çalışma,

gelecekteki tıbbi görüntüleme tekniklerinde ve tanı süreçlerinde derin öğrenme modelinin kullanımının yaygınlaşabileceğini göstermektedir. Ayrıca, bu çalışmanın sonuçları, tümör sınıflandırmasının yanı sıra tedavi planlaması ve hastalık takibi gibi diğer önemli alanlarda da potansiyel uygulamaları olduğunu göstermektedir. Gelecekte, daha büyük ve çeşitli veri setleri kullanılarak daha genelleştirici ve güvenilir sonuçlar elde edilebileceği düşünülmektedir. Bu makale, derin öğrenme modelinin beyin tümörleri konusunda umut vaat eden bir araştırma alanı olduğunu ve gelecekteki çalışmaların bu alanda daha fazla ilerleme sağlayabileceğini ortaya koymaktadır.

## 8. KAYNAKLAR

- [1] Aans.org. (2023). *Neurosurgical Conditions and Treatments Brain Tumors*. American Association of Neurological Surgeons: <https://www.aans.org/en/Patients/Neurosurgical-Conditions-and-Treatments/Brain-Tumors> adresinden alındı. (Erişim Tarihi: 7.05.2023)
- [2] Abhishek Ramanathapura Satyanarayana, M. A. (2023). Oil Spill Segmentation Using DeepEncoder-Decoder Models. *A Preprint*.
- [3] Alex Krizhevsky, I. S. (2012). ImageNet Classification with Deep Convolutional. *NIPS*.
- [4] American Society of Clinical Oncology (ASCO). (2023). *Brain Tumor: Statistics*. Cancer.net: <https://www.cancer.net/cancer-types/brain-tumor/statistics> adresinden alındı. (Erişim Tarihi: 7.05.2023)
- [5] Bin Wang, B. X. (2020). Particle Swarm Optimisation for Evolving Deep Neural Networks for Image Classification by Evolving and Stacking Transferable Blocks.
- [6] Birkan Büyükarıkan, E. Ü. (2020). Aydınlatma Özniteliği Kullanılarak Evrimsel Sinir Ağı Modelleriyle Meyve Sınıflandırma. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*.
- [7] Aslan, M. (2022). Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 399-407.
- [8] Arı, A. (2019). Derin öğrenme tabanlı beyin MR görüntülerinden beyin tümörlerinin tespit edilmesi ve sınıflandırılması.
- [9] Gurkahraman, K., & Karakış, R. (2021). Veri çoğaltma kullanılarak derin öğrenme ile beyin tümörlerinin sınıflandırılması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(2), 997-1012.
- [10] Taşcı, B. (2022). Beyin Mr Görüntülerinden mRMR Tabanlı Beyin Tümörlerinin Sınıflandırması.
- [11] Özdemir, C., Doğan, Y., & Atas, M. CNN Mimarisi ile MR Görüntülerinden Beyin Tümörlerinin Sınıflandırılması.
- [12] Arı, A., & Hanbay, D. (2019). Tumor detection in MR images of regional convolutional neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(3), 1395-1408.
- [13] Bulut, F., Kılıç, İ., & İnce, İ. F. (2018). Beyin Tümörü Tespitinde Görüntü Bölütleme Yöntemlerine Ait Başarımların Karşılaştırılması Ve Analizi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 20(58), 173-186.
- [14] Şener, A., & Ergen, B. Beyin MR Görüntüleri Üzerinde Tümör Tespitinde VGG-19 Model Tabanlı Yeni Bir Yaklaşım.
- [15] Kaplan, K. (2020). Beyin tümör tiplerinin makine öğrenmesi ve derin öğrenme tabanlı teknikler ile sınıflandırılması.

- [16] Gao Huang, Z. L. (2016). Densely Connected Convolutional Networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- [17] Ladomersky E, S. D.-M. (2019). The Coincidence Between Increasing Age, Immunosuppression, and the Incidence of Patients With Glioblastoma. *Europe PMC*.
- [18] Liu, J. S.-T. (2018). Adiabatic Quantum Computation Applied to Deep Learning Networks. *Entropy*.
- [19] Maad Shatnawi, F. A. (2023). Deep Learning and Vision-Based Early Drowning Detection. *Computer Vision for Security Applications*.
- [20] Mahtab Taheri, M. T. (2023). Noise-Tolerance GPU-based Age Estimation Using ResNet-50. *7th International Conference on Reliability and Safety Engineering*.
- [21] Mingxing Tan, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *International Conference on Machine Learning, 2019*.
- [22] Nitin Kumar, P. N. (2020). Image Forgery: Detection of Manipulated Images. *SSRN*.
- [23] Sartaj Bhuvaji, A. K. (2020). *Brain Tumor Classification (MRI)*. Kaggle: <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri> adresinden alındı. (Erişim Tarihi: 7.05.2023)
- [24] Suresh Pokharel, S. G. (2017). Offline Signature Verification Using Convolutional Neural Network.
- [25] Uçar, M. (2021). Glokom Hastalığının Evrişimli Sinir Ağı Mimarileri ile Tespiti. *DEÜ FMD*.
- [26] Zheng Jiang, K. Z. (2022). Improved VGG-16 Neural Network for Parameter Reduction. *ICAIS*.