

## ARTIFICIAL INTELLIGENCE STUDIES

## Performance Analysis of Deep Learning Architectures in Brain Tumor Classification

Çetin Erçelik<sup>a\*</sup>, Ali Arı<sup>b</sup>

## ABSTRACT

Brain tumors are uncontrolled tissue growths that develop as a result of replication errors during the cell renewal process and are classified as malignant or benign. These tumors can cause brain damage or severe health problems due to increased intracranial pressure. Generally, brain tumors are categorized into two main types: primary and secondary. Primary tumors, often benign, originate directly in the brain, whereas secondary tumors result from the metastasis of cancer cells from other organs to the brain. Early diagnosis of brain tumors is crucial for treatment planning and evaluating outcomes. This study aims to facilitate the early detection and classification of brain tumors using Magnetic Resonance Imaging (MRI). It evaluates the performance of deep learning architectures such as EfficientNet, DenseNet, and AlexNet on three different datasets containing glioma, meningioma, pituitary tumors, and tumor-free brain images. The research compares current deep learning techniques and various performance metrics to identify architectures with the highest performance. The results demonstrate that the developed methods are effective in brain tumor classification. This research aims to assist healthcare professionals in making accurate diagnoses, enabling swift and effective treatment of patients, and significantly contributing to the early diagnosis and treatment planning of brain tumors.

<sup>a\*</sup> İnönü Üniversitesi,  
Mühendislik Fakültesi,  
Yazılım Mühendisliği Bölümü  
Malatya, Türkiye  
ORCID: 0009-0009-0637-6993

<sup>b</sup> İnönü Üniversitesi,  
Mühendislik Fakültesi,  
Bilgisayar Mühendisliği Bölümü  
Malatya, Türkiye  
ORCID: 0000-0002-5071-6790

\* Corresponding author.  
e-mail: cetin.ercelik@inonu.edu.tr

**Keywords:** Brain Tumor, Classification, Deep Learning

**Anahtar Kelimeler:** Beyin Tümörü, Sınıflandırma, Derin Öğrenme

Submitted: 13.12.2024  
Revised: 25.12.2024  
Accepted: 29.12.2024

doi: 10.30855/AIS.2024.07.02.08

## Beyin Tümörü Sınıflandırılmasında Derin Öğrenme Mimarilerinin Performans Analizi

## ÖZ

Beyin tümörleri, hücre yenilenme sürecinde ortaya çıkan kopyalama hataları sonucunda gelişen malign (kötü huylu) veya benign (iyi huylu) kontrolsüz doku büyümeleridir. Bu tümörler, kafatası içindeki basıncın artmasıyla beyin hasarına veya ciddi sağlık sorunlarına neden olabilirler. Genel olarak, beyin tümörleri birincil ve ikincil olmak üzere iki ana kategoride incelenir. Birincil tümörler, genellikle benign özellikler gösterirken, beyinde doğrudan oluşur; ikincil tümörler ise diğer organlardaki kanser hücrelerinin metastaz yaparak beyine sıçramasıyla meydana gelir. Beyin tümörlerinin erken teşhisi, tedavi planlaması ve sonuçlarının değerlendirilmesi hayati önem taşımaktadır. Bu çalışma, Manyetik Rezonans Görüntüleme (MRI) kullanılarak beyin tümörlerinin erken teşhisini ve sınıflandırmasını hedeflemektedir. Araştırmada, EfficientNet, DenseNet ve AlexNet derin öğrenme mimarilerinin performans karşılaştırmaları, glioma, meningioma, pituitary tümörleri ve tümörsüz beyin görüntüleri içeren üç farklı veri seti üzerinde yapılmıştır. Çalışma, mevcut derin öğrenme teknikleri ve çeşitli performans metriklerini karşılaştırarak en yüksek performansı sunan mimarileri tespit etmektedir. Sonuçlar, geliştirilen yöntemlerin beyin tümörü sınıflandırmasında etkin olduğunu ortaya koymaktadır. Bu araştırma, sağlık profesyonellerine doğru teşhis koyma sürecinde yardımcı olarak hastaların hızlı ve etkin bir şekilde tedavi edilmesine olanak tanımayı amaçlamaktadır ve beyin tümörlerinin erken teşhisi ile tedavi planlamasında önemli bir katkı sağlamaktadır.

## 1. Giriş (Introduction)

Son yıllarda yapay zekâ, tıp ve özellikle cerrahi alanında çığır açan yeniliklere öncülük etmiştir [1]. Yapay zekâ teknolojileri, tıbbi görüntüleme analizindeki yüksek doğruluk ve büyük miktarda veriyi hızlı bir şekilde işleyebilme kabiliyetiyle, cerrahi planlamadan teşhis süreçlerine kadar pek çok alanda sağlık hizmetlerinin kalitesini artırmaktadır [2]. Bu gelişmeler, sadece tıbbi süreçlerin otomasyonunu sağlamakla kalmamakta, aynı zamanda hasta sonuçlarını iyileştiren yenilikçi yaklaşımları da beraberinde getirmektedir [3]. Özellikle cerrahi müdahaleler gibi karmaşık süreçlerde yapay zekâ, doktorlara güvenilir bir destek sunarak hataları en aza indirme potansiyeli taşımaktadır.

Yapay zekânın alt dallarından makine öğrenimi ve derin öğrenme, bu teknolojinin gelişiminde kilit bir rol oynamaktadır [4]. Makine öğrenimi algoritmaları, sağlık hizmetlerinde hızlı ve doğru karar alma süreçlerini desteklerken; derin öğrenme, özellikle tıbbi görüntülerin analizi ve sınıflandırılmasında devrim niteliğinde sonuçlar elde edilmesini sağlamaktadır [5]. Bu teknikler, görüntüleme verilerinin yorumlanmasında geleneksel yöntemlere kıyasla çok daha yüksek bir doğruluk sunmakta ve sağlık profesyonellerinin iş yükünü hafifletmektedir.

Tıbbi görüntüleme alanındaki bu teknolojik ilerlemeler, beyin tümörleri gibi karmaşık ve kritik hastalıkların teşhis ve tedavi süreçlerinde de yeni fırsatlar yaratmaktadır. Beyin tümörleri, dünya genelinde ciddi sağlık sorunlarına yol açan ve yaşam kalitesini derinden etkileyen hastalıkların başında gelmektedir. Beyin dokusundaki hücrelerin kontrolsüz ve anormal büyümesiyle ortaya çıkan bu tümörler, merkezi sinir sistemi üzerinde önemli hasarlara yol açabilmekte ve hastaların günlük yaşamında ciddi zorluklara neden olabilmektedir [6].

Beyin tümörlerinin teşhis ve sınıflandırılması, hem erken tedaviye olanak sağlaması hem de klinik sonuçları iyileştirmesi açısından hayati bir öneme sahiptir. Bu bağlamda, derin öğrenme tabanlı yaklaşımlar, tıbbi görüntüleme tekniklerinin doğru analiz edilmesi ve sınıflandırılması için yenilikçi çözümler sunarak teşhis ve tedavi süreçlerine önemli katkılar sağlamaktadır [7]. Yapay zekâ ve derin öğrenme tekniklerinin bu alandaki etkin kullanımı, beyin tümörlerinin daha hızlı ve doğru bir şekilde tanımlanmasına olanak tanımakta ve klinik uygulamaları geliştirmektedir.

Bu çalışma, beyin tümörlerinin tespiti ve sınıflandırılmasında derin öğrenme modellerinin etkinliğini değerlendirmeyi ve bu modellerin klinik uygulamalardaki potansiyel katkılarını incelemeyi amaçlamaktadır. Bu kapsamda, üç farklı açık beyin tümörü veri kümesi üzerinde EfficientNet, AlexNet ve DenseNet mimarilerinin performansları karşılaştırılmıştır. Çalışmada, bu modellerin doğruluk, duyarlılık ve kesinlik gibi önemli kriterler açısından sunduğu avantajlar detaylı bir şekilde incelenmiştir. Yapılan analizler, beyin tümörlerinin daha doğru ve hızlı bir şekilde sınıflandırılmasına olanak sağlamak ve klinik uygulamalarda yapay zekâ tabanlı yaklaşımların gerekliliğini vurgulamaktadır.

Çalışmanın organizasyonu şu şekilde düzenlenmiştir: Bölüm 1.1'de ilgili çalışmalar özetlenerek literatürdeki mevcut yaklaşımlar incelenmiştir. Bölüm 2'de kullanılan materyal ve yöntemler açıklanmış, veri kümeleri ve derin öğrenme mimarilerine dair detaylar sunulmuştur. Bölüm 3'te deneysel sonuçlar tartışılmış ve performans analizleri gerçekleştirilmiştir. Son olarak, Bölüm 4'te çalışmanın sonuçları özetlenmiş ve gelecekte yapılabilecek çalışmalar için yönlendirmeler sunulmuştur. Literatürdeki mevcut yaklaşımları irdeleyen ve bilgi birikimine katkı sağlamayı hedefleyen bu çalışma, aynı zamanda tıbbi görüntüleme süreçlerinin verimliliğini artıracak yenilikçi çözümler geliştirilmesine ışık tutmaktadır.

### 1.1. İlgili Çalışmalar (Related Works)

Beyin tümörlerinin teşhis ve sınıflandırılmasında çeşitli derin öğrenme tabanlı yöntemler, literatürde önemli bir yer tutmaktadır. Kabir ve diğerleri tarafından yapılan çalışmada, destek vektör makinesi (SVM) ve yapay sinir ağı tabanlı bir tümör tespit algoritması geliştirilmiştir. Bu algoritma, kenar koruma, görüntü iyileştirme, SVM tabanlı segmentasyon, özellik çıkarma ve sınıflandırma aşamalarını içermekte ve BRATS veri seti üzerinde %97,7 doğruluk oranı ile birçok mevcut yöntemle üstünlük sağlamaktadır [8].

Poornam ve Alagarsamy, beyin tümörlerinin MRI görüntülerinden otomatik sınıflandırılması için ResNet tabanlı bir evrişimli sinir ağı (CNN) modeli önermiştir. Görüntü ön işleme, veri artırma ve ağ

eđitimi ařamalarından oluřan bu yntem, performansını apraz dođrulama ile deđerlendirerek etkili bir sınıflandırma yaklařımı sunmuřtur [9].

Zulfiqar ve diđerleri, EfficientNet modellerini kullanarak beyin tmrlerini  sınıfa (rneđin glioma, menenjiom ve hipofiz tmr) ayıran transfer đrenimi tabanlı bir yntem geliřtirmiřtir. EfficientNetB2 modeli, CE-MRI veri setinde %98,86 dođruluk oranı ve yksek F1-skora ulařmıř; ayrıca Grad-CAM kullanımı ile tmr blgelerinin vurgulanmasını sađlamıřtır. Modelin hafif yapısı ve dřk iřlem maliyeti, dikkate deđer avantajlar arasında yer almaktadır [10].

Altun ve Alkan, MR Spektroskopisi (MRS) verilerine dayalı bir Long Short-Term Memory (LSTM) tabanlı bilgisayar destekli tanı (BDT) sistemi geliřtirmiřtir. Bu yaklařım, klasik yntemlere kıyasla %93 dođruluk oranı ile beyin tmr teřhisinde karar destek srecine nemli bir katkı sunmaktadır [11].

Gke ve diđerleri, beyin tmrlerinin MRI grntleri zerinden iřaretlenmesi iin U-Net tabanlı bir evriřimli sinir ađı geliřtirmiřtir. BRATS veri setinde eđitilen bu model, 0.908, 0.807 ve 0.877 Dice Coefficient deđerleri ile tmr blgelerini bařarılı bir Őekilde iřaretleyerek derin đrenme yntemlerinin tıbbi grnt analizindeki etkinliđini gstermiřtir [12].

Noreen ve diđerleri, Inception-v3 ve DenseNet201 modellerine dayalı ok seviyeli zellik ıkarma ve birleřtirme yntemini nererek, halka aık veri setlerinde %99,34 (Inception-v3) ve %99,51 (DenseNet201) dođruluk oranlarına ulařmıřtır. Bu yntem, mevcut tekniklere kıyasla stn performans sunmaktadır [13].

Dıaz-Pernas ve diđerleri, İnsan Grsel Sistemi'nden esinlenerek geliřtirilen tam otomatik bir beyin tmr segmentasyon ve sınıflandırma modeli sunmuřtur. Bu model, n iřleme gereksinimini ortadan kaldırarak menenjiom, glioma ve hipofiz tmrlerini sınıflandırmıř ve 3064 MRI grnts zerinde %97,3 dođruluk oranı ile mevcut yntemlerden stn performans sergilemiřtir [14].

Asif ve diđerleri, Xception, NasNet Large, DenseNet121 ve InceptionResNetV2 gibi modellerle beyin tmr teřhisi iin bir sistem geliřtirmiřtir. Xception modeli, MRI-large veri setinde %99,67, MRI-small veri setinde ise %91,94 dođruluk oranı ile en iyi performansı gstermiřtir. Bu sistem, hızlı ve dođru sınıflandırma iin etkili bir zm sunmaktadır [15].

Raza ve diđerleri, glioma, menenjiom ve hipofiz tmrlerinin sınıflandırılması iin GoogLeNet tabanlı hibrit bir derin đrenme modeli olan DeepTumorNet'i geliřtirmiřtir. Model, %99,67 dođruluk ve %100 duyarlılık oranlarıyla ileri dzey tekniklere kıyasla stn bir performans sađlamıřtır [16].

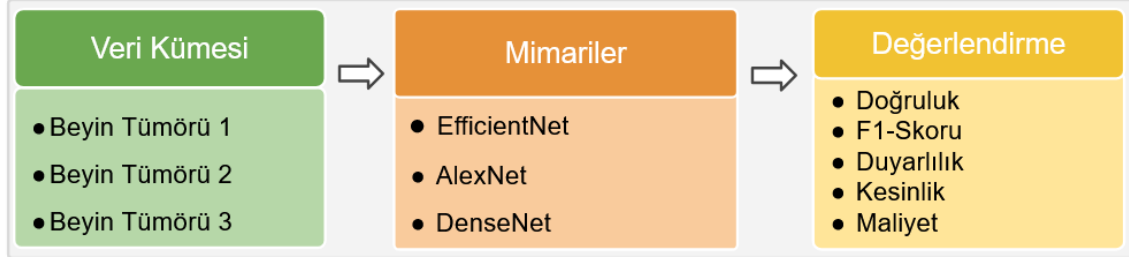
Son olarak, řahin ve diđerleri, Vision Transformer (ViT) tabanlı bir modeli Bayeři ok Amalı (BMO) optimizasyonla geliřtirerek daha yksek dođruluk, F1-skoru ve kesinlik elde etmiřtir. Optimize edilmiř modelin, iki kat daha hızlı, drt kat daha kk ve daha verimli olduđu ortaya konmuř, bu yntem sınıflandırma grevlerinde ileri dzey bir yaklařım sunmuřtur [17].

Bu alıřmalar, beyin tmrlerinin teřhis ve sınıflandırılmasında derin đrenme tabanlı yaklařımların etkinliđini ve bu yntemlerin klinik uygulamalara sađladıđu katkıyı net bir Őekilde ortaya koymaktadır.

## 2. Materyal ve Metotlar (Materials and Methods)

Derin đrenme, yapay sinir ađlarına dayanan ve verilerdeki karmařık kalıpları otomatik olarak đrenerek grevleri gerekleřtiren bir makine đrenmesi alt alanıdır [18][19]. Tıp ve diđer bilimsel alanlarda devrim yaratan bu yntem, zellikle beyin tmrlerinin teřhisi, sınıflandırılması ve MR grntlerinin segmentasyonu gibi karmařık problemler iin etkili zmler sunmaktadır. Derin đrenme modelleri, evriřim katmanları, havuzlama katmanları, aktivasyon fonksiyonları ve tam bađlantılı katmanlar gibi bileřenlerden oluřan ok katmanlı bir mimariye sahiptir [20][21]. Bu yapılar, byk veri setleri zerinde eđitildiđinde, insan benzeri kararlar alabilen, yksek performanslı modeller geliřtirilmesine olanak tanımaktadır [22].

Bu çalışmada, EfficientNet, AlexNet ve DenseNet gibi üç farklı derin öğrenme mimarisi kullanılarak beyin MRI görüntülerinin sınıflandırılması hedeflenmiştir. Çalışmada kullanılan üç açık veri seti, bu modeller üzerinde eğitilmiş ve performansları doğruluk, duyarlılık, kesinlik ve F1-skor gibi metriklerle karşılaştırılmıştır. Her bir derin öğrenme modeline ait teknik detaylar, bu bölümün alt başlıklarında ayrıntılı olarak sunulmuştur. Çalışmamızın genel akış şeması Şekil 1'de verilmiştir. Bu grafiksel özet, okuyucuya çalışmanın genel yapısını görsel bir biçimde kavrayabilme imkânı sağlamaktadır.



Şekil 1. Çalışmanın özet diyagramı (The summary diagram of the study).


## 2.1. EfficientNet Mimarisi (EfficientNet Architecture)

EfficientNet, derin öğrenme modellerinde hesaplama verimliliğini artırmayı ve daha yüksek doğruluk oranlarına ulaşmayı amaçlayan bir evrimsel sinir ağı (CNN) ailesidir. Bu mimari, 2012'den bu yana ImageNet veri kümesinde kullanılan karmaşık modellerin hesaplama yükünü optimize ederek dikkat çekmiştir. EfficientNet, B0'dan B7'ye kadar uzanan toplam sekiz modelden oluşmakta olup, bileşik ölçekleme yöntemi sayesinde derinlik, genişlik ve çözünürlük gibi boyutlar arasında dengeli bir ölçekleme sağlayarak hem yüksek doğruluk hem de hesaplama verimliliği sunmaktadır [23].

EfficientNet'in temel yapısı, MobileNetV2'de tanıtilen ancak geliştirilmiş bir versiyonu olan MBConv bloklarına dayanmaktadır [24]. Bu bloklar, şişe boyun yapısı ile kanalları genişletip sıkıştırmakta ve derin ayrılabilir evrimsel yapılar kullanarak hesaplama maliyetlerini önemli ölçüde düşürmektedir. Bunun yanı sıra, EfficientNet performansını artırmak için ReLU yerine Swish aktivasyon fonksiyonunu tercih etmektedir [25].

EfficientNet, bir temel ağın farklı ölçeklendirme boyutları arasında uygun oranları belirlemek için ızgara araması yöntemini kullanır. Bu strateji, derinlik, genişlik ve çözünürlük gibi bileşenlerin herhangi birinin darboğaz haline gelmesini önleyen optimal bir ölçekleme faktörü elde edilmesini sağlar. Örneğin, EfficientNet-B0, temel model olarak başlamakta ve bu süreç ölçeklendirme yoluyla EfficientNet-B4 gibi daha güçlü modellerin oluşturulmasına olanak tanımaktadır. Bu yenilikçi mimari, optimize edilmiş bir yapı ile yüksek doğruluk oranlarını düşük hesaplama maliyetleriyle birleştiren etkili bir çözüm sunmaktadır.

EfficientNet mimarisinin genel yapısı Şekil 2'de gösterilmektedir. Bu görsel, modelin temel bileşenlerini ve bileşik ölçekleme yönteminin mimariye olan etkisini görselleştirmektedir. EfficientNet'in bu özellikleri, sınırlı kaynaklarla dahi yüksek performanslı modeller geliştirmek için önemli bir avantaj sağlamaktadır. Çalışmamızda, EfficientNet'in performansı, beyin tümörlerini sınıflandırma görevinde diğer mimarilerle karşılaştırılmış ve etkili bir sonuç elde edilmiştir.



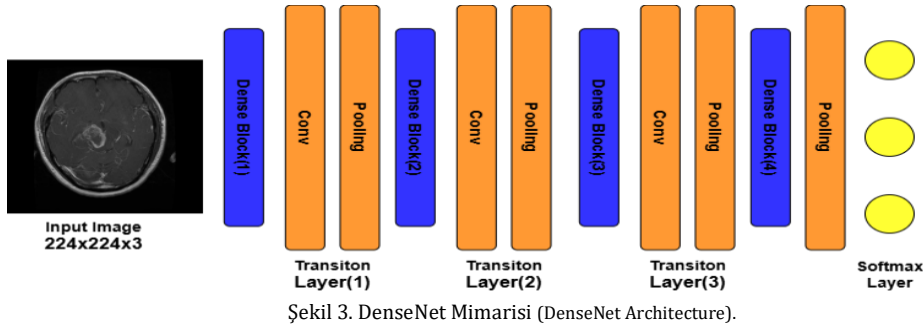
Şekil 2. EfficientNet Mimarisi (EfficientNet Architecture).

## 2.2. DenseNet Mimarisi (DenseNet Architecture)

DenseNet, katmanlar arasında yoğun bağlantılar kurarak etkili bir bilgi akışı sağlayan yenilikçi bir derin öğrenme mimarisidir. Bu mimaride, her bir katman, önceki tüm katmanlardan ek girişler alır ve kendi öznelik haritalarını (feature maps) sonraki tüm katmanlara iletir. Mevcut katmandan elde edilen çıktı öznelik haritaları, önceki katmanların çıktılarıyla birleştirilerek (concatenation) ağdaki bilgi akışının zenginleştirilmesi sağlanır. Bu yoğun bağlantı stratejisi, modelin öğrenme kapasitesini artırmakta ve bilgi kaybını azaltmaktadır.

DenseNet, geleneksel evrimsel sinir ağlarına (CNN) kıyasla daha az parametre gerektirir. Bu özellik, hesaplama verimliliğini artırmanın yanı sıra, daha küçük veri setleri üzerinde eğitilen modellerde sıkça karşılaşılan aşırı öğrenme (overfitting) problemini azaltmaktadır [26]. Ağın daha az parametreye sahip olması, modeli daha hafif ve hızlı hale getirirken, bilgi paylaşımı yoluyla doğruluk oranlarını artırmaktadır.

DenseNet mimarisinin temel yapısı Şekil 3'te gösterilmektedir. Bu görsel, her bir katmanın önceki katmanlarla nasıl yoğun bir şekilde bağlantılı olduğunu ve bu bağlantıların model performansına nasıl katkı sağladığını açıkça ortaya koymaktadır. Modelin bilgi paylaşımına dayalı bu yenilikçi yaklaşımı, beyin tümörleri gibi karmaşık sınıflandırma problemlerinde etkili çözümler sunmaktadır [26].



## 2.3. AlexNet Mimarisi (AlexNet Architecture)


AlexNet, Krizhevsky ve arkadaşları tarafından 2012 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ILSVRC-2012) tanıtılan ve derin öğrenme tabanlı görüntü işleme modellerinin gelişiminde önemli bir dönüm noktası olarak kabul edilen bir Convolutional Neural Network (CNN) modelidir [27]. LeNet-5 mimarisinden esinlenen bu model, 61 milyon parametreye ve 8 katmanlı bir yapıya sahiptir. AlexNet, giriş olarak  $227 \times 227 \times 3$  boyutunda RGB görüntüleri alır ve toplamda 5 evrişim katmanı, 3 tam bağlantılı katman ve bir Softmax katmanı içerir.

Modelde tüm evrişim ve tam bağlantılı katmanlarda ReLU aktivasyon fonksiyonu kullanılmıştır. İlk evrişim katmanı,  $11 \times 11$  boyutunda ve adım boyutu 4 olan 96 filtre içerirken, ikinci evrişim katmanı,  $5 \times 5$  boyutunda ve adım boyutu 1 olan 256 filtreden oluşur. Üçüncü, dördüncü ve beşinci evrişim katmanlarında ise filtre boyutları  $3 \times 3$  olarak belirlenmiş; üçüncü ve dördüncü katmanlarda 384, beşinci katmanda ise 256 filtre kullanılmıştır. Her evrişim katmanını takip eden ReLU aktivasyonu, modelin doğrusal olmayan ilişkileri öğrenme kapasitesini artırırken,  $3 \times 3$  boyutunda maksimum havuzlama işlemi ile boyut küçültme sağlanmıştır.

Evrşim katmanlarını takip eden 3 tam bağlantılı (fully connected, FC) katman bulunmaktadır. Bu katmanlardan sonuncusu (FC-8), 39 nörondan oluşur ve bu nöronların çıktıları, Softmax katmanı tarafından bir olasılık dağılımına dönüştürülerek giriş görüntüsünün belirli bir sınıfa ait olma olasılıkları hesaplanır. AlexNet, ImageNet veri tabanında bir milyondan fazla görüntü ve 1000'den fazla kategori üzerinde eğitilmiş ve bu süreçte modelin görüntü sınıflandırma alanındaki üstün performansı kanıtlanmıştır.

AlexNet mimarisinin genel yapısı Şekil 4'te gösterilmektedir. Bu görsel, modelin farklı katmanlarını ve

her bir katmanın sahip olduğu filtre ve aktivasyon özelliklerini detaylı bir şekilde açıklamaktadır.



Şekil 4. AlexNet Mimarisi (AlexNet Architecture).

#### 2.4. Veri Kümesi (Dataset)

Bu çalışmada kullanılan veri setleri, Kaggle platformundan temin edilen "Beyin Tümörü 1" [28], "Beyin Tümörü 2" [29] ve "Beyin Tümörü 3" [30] adlı üç farklı veri setinden oluşmaktadır. Veri setleri sırasıyla 3590, 7023 ve 7023 MRI görüntüsü içermektedir. Görüntüler, eğitim (train) ve test (test) olmak üzere iki ana klasöre ayrılmıştır. Her bir klasör, üç tümör sınıfına (Glioma, Meningioma ve Pituitary) ait görüntüleri ve tümörsüz (sağlıklı) görüntüleri barındırmaktadır. Bu yapılandırma, eğitim ve test süreçlerinde modellerin sınıflandırma performansını değerlendirmek amacıyla düzenlenmiştir. Veri kümelerinin temel istatistikleri ve dağılımları Tablo 1'de sunulmaktadır.

Beyin tümörü veri kümeleri, üç farklı tümör türüne (Pituitary, Meningioma ve Glioma) ek olarak sağlıklı beyin taramalarını içermektedir. Pituitary tümörleri, hipofiz bezinde yer alan ve hipotalamus ile birlikte çalışarak hormon salgılayan hücrelerin kontrolsüz büyümesi sonucu oluşmaktadır. Meningioma, beyin koruyucu zarları olan meninkslerden kaynaklanan bir tümör türü iken, Gliomlar, beyin destekleyici glial hücrelerinden türeyen ve çeşitli alt türleri kapsayan bir tümör grubudur. Bu kapsamlı veri setleri, beyin tümörlerinin biyolojik çeşitliliğini ve klinik önemini temsil etmektedir.

Veri kümeleri, eğitim ve test aşamalarında modellerin genel performansını değerlendirmek için dengeli bir şekilde düzenlenmiştir. Ayrıca, kapsamlı ön işleme adımları ile görüntülerin kalitesi artırılmış ve modellerin daha doğru sonuçlar üretebilmesi için uygun bir altyapı oluşturulmuştur. Bu veri setleri, beyin tümörlerinin teşhisi ve sınıflandırılması üzerine gelecekte yapılacak çalışmalara önemli bir kaynak sağlamaktadır. Dengeli dağılıma sahip eğitim ve test veri setleri, derin öğrenme tabanlı modellerin klinik uygulamalarda daha güvenilir ve etkili sonuçlar vermesine olanak tanımaktadır.

Tablo 1: Beyin tümörü veri setleri sınıf dağılımları (Class distributions of brain tumor datasets).

Sınıflar	Beyin Tümörü 1		Beyin Tümörü 2		Beyin Tümörü 3	
	Veri Sayısı	Yüzde	Veri Sayısı	Yüzde	Veri Sayısı	Yüzde
<b>Glioma</b>	985	27.59%	1621	23.08%	1621	23,08%
<b>Meningioma</b>	990	27.73%	1645	23.42%	1645	23,42%
<b>Pituitary</b>	999	27.98%	1757	25.02%	1757	25,01%
<b>Tümörsüz</b>	596	16.69%	2000	28.48%	2000	28,47%

#### 2.5. Performans Değerlendirme ve Karmaşıklık Matrisi (Performance Evaluation and Complexity Matrix)

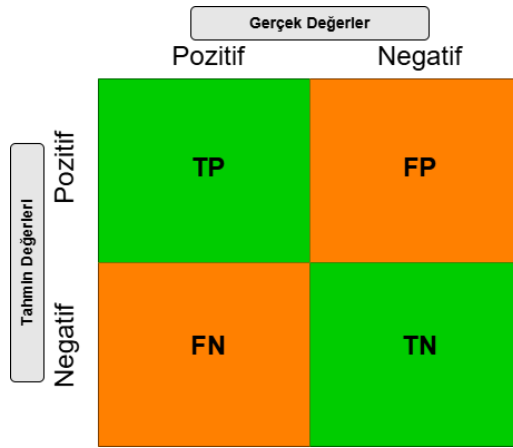
Performans değerlendirmesi, sınıflandırma doğruluğunu ve genel başarımı ölçmek için karmaşıklık matrisi kullanılarak gerçekleştirilmiştir. Karmaşıklık matrisi, bir modelin gerçek değerler ile tahmin edilen değerler arasındaki ilişkiyi detaylı bir şekilde gösteren bir yöntemdir. Matrisin dört temel bileşeni bulunmaktadır:

- Doğru Pozitif (TP): Doğru bir şekilde pozitif olarak tahmin edilen örnekler.
- Doğru Negatif (TN): Doğru bir şekilde negatif olarak tahmin edilen örnekler.
- Yanlış Pozitif (FP): Yanlış bir şekilde pozitif olarak tahmin edilen örnekler.
- Yanlış Negatif (FN): Yanlış bir şekilde negatif olarak tahmin edilen örnekler.



Bu bileşenler, modellerin sınıflandırma doğruluğunu ölçmenin yanı sıra hatalarını analiz etmede önemli bilgiler sağlamaktadır. Karmaşıklık matrisi, modelin performansını istatistiksel ve görsel açıdan analiz etmek için etkili bir araçtır ve yapay zekâ, veri madenciliği ve makine öğrenimi gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. Çalışmamızda kullanılan karmaşıklık matrisi, modellerin doğru sınıflandırma oranlarını ve hata türlerini detaylı bir şekilde ortaya koymuştur.

Karmaşıklık matrisinin görsel bir örneği Şekil 5'te sunulmaktadır. Bu görsel, matrisin yapısını ve her bir bileşenin nasıl hesaplandığını somut bir şekilde açıklayarak, okuyucunun analiz sürecini daha iyi anlamasına yardımcı olmaktadır.



Şekil 5. Karmaşıklık Matrisi (Confusion Matrix)

Ayrıca, karmaşıklık matrisine dayalı olarak hesaplanan doğruluk, duyarlılık, kesinlik ve F1-skor gibi performans metrikleri, modellerin performanslarının karşılaştırılmasında önemli bir rol oynamıştır. Bu metrikler, bir modelin hem genel başarımını hem de spesifik sınıflandırma görevlerindeki etkinliğini ölçmede kritik öneme sahiptir.

**Doğruluk (Accuracy):** Bir sınıflandırıcının başarısını değerlendiren ve doğru tahminlerin toplam tahminlere oranını ifade eden yaygın bir ölçüttür. Ancak, sınıf dağılımı dengesiz olduğunda doğruluk yanıltıcı olabilir; çoğunluk sınıfındaki doğru tahminler yüksek doğruluk sağlarken, azınlık sınıflarındaki hatalar göz ardı edilebilir [31]. Bu nedenle, modelin performansını daha kapsamlı değerlendirmek için doğruluğun yanı sıra diğer ölçütlerin de kullanılması önemlidir. Denklem 1'de doğruluk metriğinin formülü bulunmaktadır [32].

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

**Kesinlik (Precision):** Kesinlik, modelin pozitif olarak tahmin ettiği sonuçların ne kadarının gerçekte doğru olduğunu ölçer. Bu metrik, modelin yanlış pozitiflerden kaçınma konusundaki başarısını gösterir. Örneğin, bir modelin tahmin ettiği pozitif örneklerin çoğunluğu gerçekten doğruysa, modelin hassasiyeti yüksektir. Bu durum özellikle yanlış pozitiflerin ciddi sorunlara yol açtığı alanlarda, örneğin bir tıbbi teşhis sisteminde, son derece önemlidir. Denklem 2'de kesinlik metriğinin formülü bulunmaktadır.

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

**Duyarlılık (Recall):** Duyarlılık, modelin tüm gerçek pozitif örnekleri ne kadar iyi tespit edebildiğini ölçer. Bu metrik, yanlış negatiflerden kaçınmaya odaklanır ve gerçek pozitiflerin ne kadarının model tarafından doğru tahmin edilebildiğini gösterir. Yüksek bir geri çağırma, modelin mümkün olduğunca fazla pozitif örneği tespit etme başarısını ifade eder. Bu, özellikle eksik tespitlerin riskli olduğu durumlarda, örneğin güvenlik sistemlerinde veya hastalık taramalarında, kritik öneme sahiptir. Duyarlılık metriğine ait formülasyon denklem 3'te verilmiştir.

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

**F1-Skoru:** F1 skoru, sınıf dengesizliği olan veri kümelerinde model performansını değerlendirmek için kullanılan bir metriktir. Kesinlik ve duyarlılığı harmonik ortalamayla birleştirerek doğruluğa kıyasla daha güvenilir bir ölçüm sunar. F1 puanını maksimize etmek, hem kesinliğin hem de duyarlılığın optimize edilmesini sağladığı için, genellikle doğruluk yerine tercih edilmektedir. Denklem 4'te F1 skorunun formülü bulunmaktadır [33].

$$\text{F1 Skoru} = \frac{2 \times (\text{Kesinlik} \times \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})} \quad (4)$$

**Kayıp (Loss):** Kayıp fonksiyonu, bir modelin tahminlerinin gerçek değerlerden ne kadar farklı olduğunu ölçen ve modeli optimize ederek eğitim sürecini yönlendiren bir araçtır. Düşük kayıp, tahminlerin gerçek değerlere yakın olduğunu, yüksek kayıp ise hatalı tahminleri ifade eder. Kayıp değeri 0 olduğunda, model gerçek değerlere tamamen uyum sağlamış demektir.

Bu çalışmada AlexNet, EfficientNet ve DenseNet derin öğrenme modelleri için CrossEntropyLoss kayıp fonksiyonu kullanılmıştır. CrossEntropyLoss, özellikle çok sınıflı sınıflandırma problemlerinde tahmin edilen sınıf dağılımı ile gerçek sınıf dağılımı arasındaki farkı minimize etmeye yönelik bir kayıp fonksiyonudur. Bu kayıp fonksiyonu, çalışmadaki modellerin çıktılarının gerçek etiketlere daha iyi yaklaşmasını sağlamak ve eğitim sürecini optimize etmek amacıyla tercih edilmiştir.

### 3. Deneysel Sonuçlar (Experimental Results)

Bu çalışmada, Kaggle platformundan elde edilen üç [28], [29], [30] farklı veri seti üzerinde derin öğrenme modellerinin performansları karşılaştırmalı olarak analiz edilmiştir. EfficientNet, DenseNet ve AlexNet modelleri, aynı veri setleri üzerinde eğitilmiş ve bu modellerin sınıflandırma performansları detaylı değerlendirme metrikleri ile karşılaştırılmıştır. Modellerin eğitim süreçleri boyunca aynı veri kümeleri kullanılarak, sonuçlar tutarlı ve adil bir şekilde analiz edilmiştir. Sonuçlara ilişkin detaylar Tablo 2'de sunulmaktadır.

Tablo 2: Derin öğrenme modellerinin sonuç tablosu (Results table of deep learning models).

Veri kümeleri	Mimariler	Doğruluk	Duyarlılık	Kesinlik	F1-skoru	Kayıp
Beyin Tümörü 1	EfficientNet	0.995	0.995	0.995	0.995	0.016
	DenseNet	0.989	0.989	0.989	0.989	0.025
	AlexNet	0.975	0.975	0.975	0.975	0.081
Beyin Tümörü 2	EfficientNet	0.973	0.973	0.973	0.973	0.135
	DenseNet	0.967	0.967	0.968	0.967	0.192
	AlexNet	0.930	0.930	0.932	0.930	0.377
Beyin Tümörü 3	EfficientNet	0.996	0.996	0.996	0.996	0.012
	DenseNet	0.999	0.999	0.999	0.999	0.005
	AlexNet	0.974	0.974	0.975	0.974	0.109

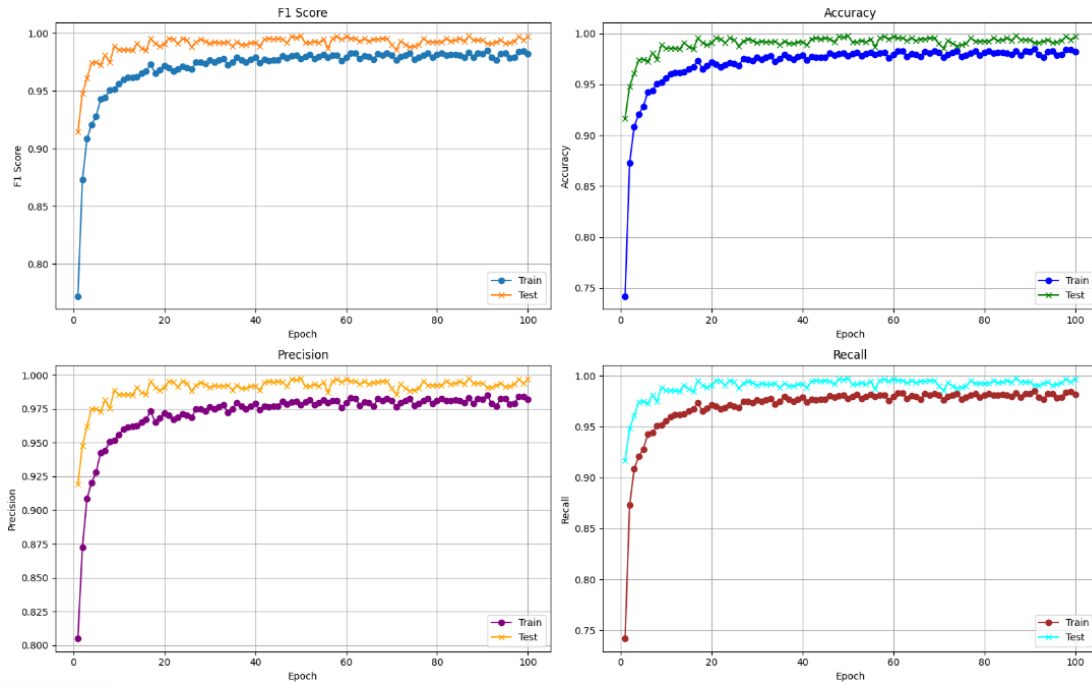
İlk veri seti olan Beyin Tümörü 1 üzerinde yapılan analizlerde, EfficientNet modeli, 0.995 doğruluk, recall, precision ve F1 skoru ile en yüksek performansı göstermiştir. Ayrıca, modelin 0.016 gibi düşük bir kayıp değerine sahip olması, hem stabil hem de güvenilir bir şekilde çalıştığını ortaya koymaktadır. DenseNet, 0.989 doğruluk oranı ve benzer metrik değerlerle EfficientNet'e yakın bir performans sergilemiştir. Ancak, 0.025'lik kayıp değeri nedeniyle bir miktar geride kalmıştır. AlexNet ise 0.975 doğruluk oranı ile daha düşük performans göstermiş ve 0.081 gibi yüksek bir kayıp değeriyle diğer iki modelin gerisinde kalmıştır.



Beyin Tümörü 2 veri seti üzerinde yapılan değerlendirmelerde, EfficientNet modeli, 0.973 doğruluk, recall, precision ve F1 skoru ile yine en iyi performansı sergilemiştir. Modelin 0.135'lik kayıp değeri, diğer modellere kıyasla daha yüksek bir stabilite sunduğunu göstermektedir. DenseNet, 0.967 doğruluk ve precision değerlerinde başarılı bir performans ortaya koymuş, ancak 0.192'lik kayıp değeri nedeniyle EfficientNet'in gerisinde kalmıştır. AlexNet ise bu veri setinde de 0.930 doğruluk ve precision değerleri ile düşük bir performans göstermiş, 0.377'lik kayıp değeri ile daha az başarılı bulunmuştur.

Son veri seti olan Beyin Tümörü 3 üzerinde, EfficientNet ve DenseNet modelleri oldukça yüksek performans göstermiştir. EfficientNet, 0.996 doğruluk oranı ve 0.012 kayıp değeri ile en tutarlı sonuçları elde etmiştir. DenseNet, 0.999 doğruluk ve precision değerleri ile öne çıkmış olsa da, 0.005 kayıp değeri EfficientNet'e kıyasla biraz daha yüksek bulunmuştur. AlexNet, 0.974 doğruluk ve 0.109 kayıp değerleri ile bu veri setinde de diğer modellerin gerisinde kalmıştır.

Genel olarak, EfficientNet, tüm veri setlerinde en yüksek doğruluk oranı ve en düşük kayıp değerleriyle en başarılı model olarak öne çıkmıştır. DenseNet, doğruluk ve precision metriklerinde EfficientNet'e yakın performans sergilemiş, ancak daha yüksek kayıp değerleri nedeniyle geride kalmıştır. AlexNet ise her üç veri setinde de düşük performans göstermiş ve daha yüksek kayıp değerleriyle dikkat çekmiştir. Bu sonuçlar, EfficientNet modelinin beyin tümörü sınıflandırma problemleri için en uygun model olduğunu açıkça ortaya koymaktadır. EfficientNet modeline ait eğitim (train) ve test sonuçlarının görselleştirilmiş hali Şekil 6'da sunulmaktadır.



Şekil 6. EfficientNet model eğitimi grafiğinin sonucu (The result of the EfficientNet model training graph).

#### 4. Sonuçlar (Conclusion)

Bu çalışmada, EfficientNet, DenseNet ve AlexNet gibi üç farklı derin öğrenme modelinin Kaggle platformundan elde edilen üç veri seti üzerindeki görüntü sınıflandırma performansları karşılaştırmalı olarak değerlendirilmiştir. Çalışmanın ilk aşamasında, veri setleri derin öğrenme modelleri için uygun hale getirilmiş ve çeşitli veri ön işleme teknikleri uygulanmıştır. Modeller, her biri 100 epoch boyunca eğitilmiş ve performansları doğruluk, hassasiyet, duyarlılık ve F1 skoru gibi değerlendirme metrikleri ile analiz edilmiştir.

Sonuçlar, beyin tümörlerinin teşhis ve sınıflandırılmasında derin öğrenme modellerinin genel olarak yüksek performans sergilediğini ortaya koymuştur. Özellikle EfficientNet, tüm veri setlerinde en iyi sonuçları elde ederek doğruluk ve kayıp değerleri açısından diğer modellere üstünlük sağlamıştır. EfficientNet'in başarısı, hem sınıflandırma doğruluğundaki yüksek oranlar hem de düşük kayıp

değerleriyle desteklenmiştir. DenseNet, EfficientNet'e yakın bir performans göstermiş olmasına rağmen, kayıp değerleri nedeniyle EfficientNet'in gerisinde kalmıştır. AlexNet ise diğer iki modelden daha düşük sonuçlar sergilemiş ve özellikle kayıp değerlerinin yüksek olması nedeniyle daha az başarılı bulunmuştur. Bu bulgular, EfficientNet'in beyin tümörü sınıflandırma problemleri için etkili ve güvenilir bir çözüm sunduğunu kanıtlamaktadır.

Çalışmanın sonuçları, derin öğrenme modellerinin beyin tümörü teşhisi ve sınıflandırmasında önemli bir potansiyel sunduğunu göstermektedir. Bu modeller, erken teşhis ve doğru sınıflandırma ile tedavi planlamasının optimize edilmesine katkı sağlamaktadır. Özellikle erken ve doğru teşhis, hastaların tedavi süreçlerinin iyileştirilmesi ve klinik sonuçların olumlu yönde etkilenmesi açısından kritik bir öneme sahiptir. Bunun yanı sıra, bu teknolojiler, doktorların daha doğru ve hızlı kararlar almasına olanak tanyarak sağlık sektöründe önemli bir dönüşüm sağlamaktadır.

**Kısıtlamalar:** Bu çalışmanın bazı sınırlamaları bulunmaktadır. Veri setleri, Kaggle platformundan elde edilen hazır veri kaynaklarına dayandığından, modellerin gerçek dünya klinik verileri üzerindeki performansı bu çalışmada değerlendirilememiştir. Gerçek dünya verilerindeki dengesizlikler ve farklılıklar, modellerin performansını etkileyebilecek bir unsur olarak ileride ele alınabilir. Ayrıca, bu çalışmada yalnızca üç model incelenmiş olup, diğer modern derin öğrenme mimarilerinin performansları değerlendirilmemiştir. Bununla birlikte, kullanılan modellerin kapsamlı bir analizinin yapılmış olması, sonuçların güvenilirliğini ve çalışmanın genel katkısını artırmaktadır.

**Gelecekteki Yönelimler:** Bu çalışmanın sonuçları, gelecekte yapılacak çalışmalar için çeşitli yönlendirmeler sunmaktadır. İlk olarak, gerçek dünya klinik verileri kullanılarak modellerin performansının değerlendirilmesi, çalışmanın sonuçlarının daha geniş bir bağlamda doğrulanmasını sağlayabilir. Ayrıca, transfer öğrenimi, model optimizasyon teknikleri ve veri artırma stratejileri gibi yöntemlerle modellerin performansı daha da iyileştirilebilir. Bunun yanı sıra, farklı derin öğrenme mimarilerinin ve hibrit yaklaşımların performanslarının karşılaştırıldığı çalışmalar, beyin tümörü teşhisi ve sınıflandırması alanına yeni katkılar sunabilir. Son olarak, bu modellerin klinik karar destek sistemlerine entegrasyonu üzerine çalışmalar yapılması, yapay zekâ tabanlı çözümlerin sağlık sektöründe daha etkili bir şekilde kullanılmasını sağlayabilir.

## Kaynaklar (References)

- [1] Altun Güven Sara, Fatih Talu Muhammed, B. M. Bölümü, and İ. Üniversitesi, "Beyin Tümörü Bölütleme ve Algılamada Yeni Çekişmeli Üretken Ağ Kullanılması Using a New Generative Adversarial Network in Brain Tumor Segmentation and Detection," *Journal of Computer Science*, pp. 68–79, 2022, doi: 10.53070/bbd.1172664.
- [2] R. Tamilselvi, A. Nagaraj, M. P. Beham, and M. B. Sandhiya, "BRAMSIT: A Database for Brain Tumor Diagnosis and Detection," *2020 6th International Conference on Bio Signals, Images, and Instrumentation, ICBSII 2020*, Feb. 2020, doi: 10.1109/ICBSII49132.2020.9167530.
- [3] A. Işin, C. Direkoğlu, and M. Şah, "Review of MRI-based Brain Tumor Image Segmentation Using Deep Learning Methods," *Procedia Comput Sci*, vol. 102, pp. 317–324, Jan. 2016, doi: 10.1016/J.PROCS.2016.09.407.
- [4] E. Hanbay and A. Arı, "Özel Blok Yapıları Kullanarak Tasarlanan Derin Öğrenme Mimarileri ile Alzheimer Hastalık Tespiti," *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 35, no. 2, pp. 745–752, Sep. 2023, doi: 10.35234/FUMBD.1313523.
- [5] M. Şahin, E. Şahin, E. Özdemir, M. F. Talu, and S. Öztürk, "Beyin tümörü biyopsisi için derin öğrenme tabanlı risk minimizasyonlu otomatik planlama," *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, vol. 40, no. 1, pp. 487–500, Aug. 2024, doi: 10.17341/GAZIMMFD.1348325.
- [6] E. ŞAHİN, N. N. Arslan, and D. Özdemir, "Unlocking the black box: an in-depth review on interpretability, explainability, and reliability in deep learning," *Neural Computing and Applications 2024*, pp. 1–107, Nov. 2024, doi: 10.1007/S00521-024-10437-2.
- [7] A. Gül Eker *et al.*, "Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları," *Acta Infologica*, vol. 5, no. 2, pp. 459–474, Dec. 2021, doi: 10.26650/ACIN.927561.
- [8] M. A. Kabir, "Early Stage Brain Tumor Detection on MRI Image Using a Hybrid Technique," *2020 IEEE Region 10 Symposium, TENSYP 2020*, pp. 1828–1831, Jun. 2020, doi: 10.1109/TENSYP50017.2020.9230635.
- [9] S. Poornam and S. Alagarsamy, "Detection of Brain Tumor in MRI Images using Deep Learning Method," *3rd International Conference on Electronics and Sustainable Communication Systems, ICESC 2022 - Proceedings*, pp. 855–859, 2022, doi: 10.1109/ICESC54411.2022.9885583.
- [10] F. Zulfiqar, U. Ijaz Bajwa, and Y. Mehmood, "Multi-class classification of brain tumor types from MR images using EfficientNets," *Biomed Signal Process Control*, vol. 84, p. 104777, Jul. 2023, doi: 10.1016/J.BSPC.2023.104777.
- [11] S. Altun and A. Alkan, "MR Spektroskopi kullanılarak beyin tümörü tespitinde LSTM tabanlı derin öğrenme uygulaması," *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, vol. 38, no. 2, pp. 1193–1202, Oct. 2022, doi: 10.17341/GAZIMMFD.1069632.
- [12] E. Gökçe, M. F. Demiral, A. H. Işık, and M. Bilen, "Evrışimli Sinir Ağlarında Beyin Tümörü Segmentasyonu," *El-Cezeri*, vol. 9, no. 4, pp. 1518–1528, Dec. 2022, doi: 10.31202/ECJSE.1141335.
- [13] N. Noreen, S. Palaniappan, A. Qayyum, I. Ahmad, M. Imran, and M. Shoaib, "A Deep Learning Model Based on

- Concatenation Approach for the Diagnosis of Brain Tumor," *IEEE Access*, vol. 8, pp. 55135–55144, 2020, doi: 10.1109/ACCESS.2020.2978629.
- [14] F. J. Díaz-Pernas, M. Martínez-Zarzuela, D. González-Ortega, and M. Antón-Rodríguez, "A Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network," *Healthcare 2021, Vol. 9, Page 153*, vol. 9, no. 2, p. 153, Feb. 2021, doi: 10.3390/HEALTHCARE9020153.
- [15] S. Asif, W. Yi, Q. U. Ain, J. Hou, T. Yi, and J. Si, "Improving Effectiveness of Different Deep Transfer Learning-Based Models for Detecting Brain Tumors From MR Images," *IEEE Access*, vol. 10, pp. 34716–34730, 2022, doi: 10.1109/ACCESS.2022.3153306.
- [16] A. Raza *et al.*, "A Hybrid Deep Learning-Based Approach for Brain Tumor Classification," *Electronics 2022, Vol. 11, Page 1146*, vol. 11, no. 7, p. 1146, Apr. 2022, doi: 10.3390/ELECTRONICS11071146.
- [17] E. Şahin, D. Özdemir, and H. Temurtaş, "Multi-objective optimization of ViT architecture for efficient brain tumor classification," *Biomed Signal Process Control*, vol. 91, p. 105938, May 2024, doi: 10.1016/J.BSPC.2023.105938.
- [18] G. Arslan, F. Aydemir, and S. Arslan, "Enhanced license plate recognition using deep learning and block-based approach," *Journal of Scientific Reports-A*, no. 058, pp. 57–82, Sep. 2024, doi: 10.59313/JSR-A.1505302.
- [19] C. Erçelik and K. I. Hanbay, "Effects of Some Deep Learning Models with Power Law Transformation on Brain Tumor Classification," *8th International Artificial Intelligence and Data Processing Symposium, IDAP 2024*, 2024, doi: 10.1109/IDAP64064.2024.10710909.
- [20] S. Dörterler, S. Arslan, and D. Özdemir, "Unlocking the potential: A review of artificial intelligence applications in wind energy," *Expert Syst*, vol. 41, no. 12, p. e13716, Dec. 2024, doi: 10.1111/EXSY.13716.
- [21] X. Zhai and F. Qiao, "A Deep Learning Model with Adaptive Learning Rate for Fault Diagnosis," *Proceedings of 2020 IEEE 9th Data Driven Control and Learning Systems Conference, DDCLS 2020*, pp. 668–673, Nov. 2020, doi: 10.1109/DDCLS49620.2020.9275094.
- [22] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature 2015 521:7553*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [23] Ü. Atila, M. Uçar, K. Akyol, and E. Uçar, "Plant leaf disease classification using EfficientNet deep learning model," *Ecol Inform*, vol. 61, p. 101182, Mar. 2021, doi: 10.1016/J.ECOINF.2020.101182.
- [24] B. G. Arı, H. Üzen, and A. Şengür, "Accurate Segmentation of Brain Tumors in Magnetic Resonance Images with Pyramid Stage Decomposition Network Approach," *32nd IEEE Conference on Signal Processing and Communications Applications, SIU 2024 - Proceedings*, 2024, doi: 10.1109/SIU61531.2024.10600920.
- [25] İ. Kunduracıoğlu and İ. Paçal, "Deep Learning-Based Disease Detection in Sugarcane Leaves: Evaluating EfficientNet Models," *Journal of Operations Intelligence*, vol. 2, no. 1, pp. 321–235, Aug. 2024, doi: 10.31181/JOPI21202423.
- [26] F. Yuwei *et al.*, "Partial Discharge Pattern Recognition Method Based on Transfer Learning and DenseNet Model," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 30, no. 3, pp. 1240–1246, Jun. 2023, doi: 10.1109/TDEI.2023.3239032.
- [27] W. Ketwongsa, S. Boonlue, and U. Kokaew, "A New Deep Learning Model for the Classification of Poisonous and Edible Mushrooms Based on Improved AlexNet Convolutional Neural Network," *Applied Sciences 2022, Vol. 12, Page 3409*, vol. 12, no. 7, p. 3409, Mar. 2022, doi: 10.3390/APP12073409.
- [28] M. Hamdy, "brain tumor mri classification." Accessed: Dec. 08, 2024. [Online]. Available: <https://www.kaggle.com/datasets/mohammedhamdy98/brain-tumor-mri-classification/>
- [29] M. Nickparvar, "Brain Tumor MRI Dataset." Accessed: Dec. 11, 2024. [Online]. Available: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>
- [30] A. Komaravolu, "Brain Tumor MRI Images." Accessed: Dec. 11, 2024. [Online]. Available: <https://www.kaggle.com/datasets/adityakomaravolu/brain-tumor-mri-images>
- [31] S. A. Güven, E. Şahin, and M. F. Talu, "Image-to-Image Translation with CNN Based Perceptual Similarity Metrics," *Computer Science*, vol. 9, no. Issue:1, pp. 84–98, Jun. 2024, doi: 10.53070/BBD.1429596.
- [32] O. Yıldız, "Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study," *JOURNAL OF THE FACULTY OF ENGINEERING AND ARCHITECTURE OF GAZI UNIVERSITY*, vol. 34, no. 4, pp. 2241–2260, 2019, doi: 10.17341/GAZIMMFD.435217.
- [33] A. Aktaş, B. Doğan, and Ö. Demir, "Derin öğrenme yöntemleri ile dokunsal parke yüzeyi tespiti," *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, vol. 35, no. 3, pp. 1685–1700, Apr. 2020, doi: 10.17341/GAZIMMFD.652101.

