

T.C.  
FIRAT ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ



BEYİN TÜMÖRÜNÜN MANYETİK REZONANS  
GÖRÜNTÜLERİ ÜZERİNDEN DERİN ÖĞRENME  
YAKLAŞIMLARIYLA ERKEN TEŞHİSİ VE  
SINIFLANDIRILMASI

Aynur SEVİNÇ

Doktora Tezi

TEKNOLOJİ VE BİLGİ YÖNETİMİ ANA BİLİM DALI

Teknoloji ve Bilgi Yönetimi Programı

MART 2025

T.C.  
FIRAT ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ

TEKNOLOJİ VE BİLGİ YÖNETİMİ ANA BİLİM DALI

Doktora Tezi

BEYİN TÜMÖRÜNÜN MANYETİK REZONANS  
GÖRÜNTÜLERİ ÜZERİNDEN DERİN ÖĞRENME  
YAKLAŞIMLARIYLA ERKEN TEŞHİSİ VE  
SINIFLANDIRILMASI

Tez Yazarı  
Aynur SEVİNÇ

Danışman  
Doç. Dr. Buket KAYA

MART 2025

ELAZIĞ

T.C.  
FIRAT ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
TEKNOLOJİ VE BİLGİ YÖNETİMİ ANA BİLİM DALI

Doktora Tezi

<b>Başlığı:</b>	<b>Beyin Tümörünün Manyetik Rezonans Görüntüleri Üzerinden Derin Öğrenme Yaklaşımlarıyla Erken Teşhisi ve Sınıflandırılması</b>
<b>Yazarı:</b>	Aynur SEVİNÇ
<b>Tez Öneri Tarihi:</b>	06.01.2022
<b>Savunma Tarihi:</b>	24.03.2025

TEZ ONAYI

Fırat Üniversitesi Sosyal Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ/OYÇOKLUĞU ile kabul edilmiştir.

İmza

<b>Danışman:</b>	<b>Doç. Dr. Buket KAYA</b> Fırat Üniversitesi Elazığ Organize Sanayi Bölgesi Meslek Yüksekokulu
<b>Başkan:</b>	<b>Prof. Dr. İbrahim TÜRKOĞLU</b> Fırat Üniversitesi Teknoloji Fakültesi
<b>Üye:</b>	<b>Doç. Dr. Bihter DAŞ</b> Fırat Üniversitesi Teknoloji Fakültesi
<b>Üye:</b>	<b>Doç. Dr. Serpil ASLAN</b> Malatya Turgut Özal Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi
<b>Üye:</b>	<b>Dr. Öğr. Üyesi Emrah ASLAN</b> Mardin Artuklu Üniversitesi Mühendislik Mimarlık Fakültesi

Bu tez, Enstitü Yönetim Kurulunun ...../...../20..... tarihli toplantısında  
tescillenmiştir.

Unvan, Adı ve SOYADI

Enstitü Müdürü

## BEYAN

Fırat Üniversitesi Sosyal Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “**BEYİN TUMÖRÜNÜN MANYETİK REZONANS GÖRÜNTÜLERİ ÜZERİNDEN DERİN ÖĞRENME YAKLAŞIMLARIYLA ERKEN TEŞHİSİ VE SINIFLANDIRILMASI**” Başlıklı Doktora Tezi’nin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

24.03.2025

**Aynur SEVİNÇ**



## ÖN SÖZ

Bu tez çalışması, derin öğrenme tekniklerinin kullanılarak beyin tümörünün tespiti ve sınıflandırılması üzerine önerilen yaklaşımları içermektedir. Bu çalışmanın arkasındaki motivasyon, en ölümcül hastalıklardan biri olarak kabul edilen beyin tümörlerinin erken aşamada teşhis edilmesine ve tanıyla doğru sınıflandırılmasına duyulan ihtiyaçtan kaynaklanmakta ve bu hastaya uygulanacak tedavi sonuçlarını önemli ölçüde etkilemektedir. Aksi durumda beyin tümörlerinin eksik veya yanlış tespiti, insan ömrünün kısalması gibi önemli istenmeyen sonuçlara yol açabilir. Bu bağlamda, doğru teşhis ve yüksek doğrulukla tümör türünü sınıflandıran Yapay Zekâ destekli sistemler üzerine çalışılmaktadır. Bu araştırmada da beyin Manyetik Rezonans görüntüleri kullanılarak beyin tümörünün yüksek doğrulukla tespit edilmesi, tanımlanması, sınıflandırılması amacıyla geliştirdiğimiz derin öğrenme modellerinin başarısı değerlendirilmektedir. Çalışmamızın kapsamlı deneyleri ve analizleri sonucunda, tıbbi görüntülerden beyin tümörlerinin otomatik tespiti için sağlam ve güvenilir bir sistem geliştirilmiştir. Bu hem zorlu hem de öğretici çalışma sürecinde üzerimde emeği olan birçok kişiye teşekkürlerimi arz etmek isterim;

Doktora eğitimim boyunca ve bu tez çalışması sürecinde bilgi ve deneyimlerini benden esirgemeyen, her aşamada destek olan, rehberliği ve fikirleriyle sürekli gelişimimi sağlayan Değerli Danışman Hocam Sayın Doç. Dr. Buket KAYA'ya,

Yapıcı görüşleri, kıymetli geri bildirimleri ve yol gösterici önerileriyle bu araştırma çalışmasının gelişimine katkı sağlayan Değerli Jüri Üyeleri; Sayın Prof. Dr. İbrahim TÜRKOĞLU'na, Sayın Doç. Dr. Bihter DAŞ'a, Sayın Dr. Öğr. Üyesi Emrah ASLAN'a ve Sayın Doç. Dr. Serpil ASLAN'a;

Tez süreci boyunca ilgi, anlayış ve desteğini eksik etmeyen Değerli Kız Kardeşim Ayşe Nehir SEVİNÇ'e;

Ve beni akademik hayata teşvik eden, hayatımın her döneminde yanımda olan, her türlü maddi ve manevi hiçbir desteğini esirgemeyen Kıymetli Ailem ve varlığıyla hayatıma büyük anlam katan Sevgili Annem'e;

*Sonsuz Teşekkürler..*

**Aynur SEVİNÇ**

ELAZIĞ 2025

# İÇİNDEKİLER

BEYAN.....	I
ÖN SÖZ.....	II
İÇİNDEKİLER.....	III
ÖZET.....	V
ABSTRACT.....	VII
ŞEKİLLER LİSTESİ.....	IX
TABLolar LİSTESİ.....	X
EKLER LİSTESİ.....	XI
SİMGELER.....	XII
KISALTMALAR.....	XIII
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1. Araştırmanın Amacı.....	3
1.2. Araştırmanın Önemi.....	3
1.3. Zorluklar ve Sınırlılıklar.....	4
1.4. Literatür Özeti.....	4
1.5. Tezin Yapısı.....	6
<b>2. BEYİN TÜMÖRÜ.....</b>	<b>8</b>
2.1. Beyin Tümörünün Oluşma Nedenleri ve En Sık Görülen Belirtileri.....	10
2.2. Beyin Tümörü Türleri.....	10
2.2.1. Glioma.....	11
2.2.1.1. Astrositom.....	11
2.2.1.2. Glioblastom.....	11
2.2.1.3. Oligodendroglioma.....	12
2.2.1.4. Ependimom.....	12
2.2.2. Meningioma.....	12
2.2.3. Pituitary.....	13
2.3. Beyin Tümörleri İçin Kullanılan Görüntüleme Teknikleri.....	13
2.3.1. Bilgisayarlı Tomografi.....	14
2.3.2. Manyetik Rezonans Görüntüleme.....	15
2.3.3. Direk Grafi.....	16
2.3.4. Anjiogram.....	16
2.3.5. PET/BT.....	16
<b>3. YAPAY ZEKÂ.....</b>	<b>17</b>
3.1. Makine Öğrenmesi.....	17
3.2. Yapay Sinir Ağları.....	18
3.3. Derin Öğrenme.....	23
3.3.1. Derin Öğrenme Kütüphaneleri.....	26
3.3.2. Evrişimsel Sinir Ağları.....	27
3.3.3. VGG-16 Evrişimli Ağ.....	28
3.3.4. Vision Transformer (ViT) Modeli.....	29
<b>4. MATERYAL ve METOT.....</b>	<b>31</b>
4.1. Veri Temin Süreci.....	31
4.2. Veri Seti-1.....	31
4.3. Veri Seti-2.....	32
4.4. Veri Seti-3.....	33
4.5. Önerilen Metodoloji.....	34
4.6. Ön İşleme.....	34

4.6.1. Normalizasyon, Görüntü Kırpma ve Yeniden Boyutlandırma .....	35
<b>5. BULGULAR.....</b>	<b>37</b>
5.1. ESA, VGG-16 Yaklaşımına Dayalı Derin Öğrenme Kullanılarak Beyin Tümörünün Tespit Edilmesine İlişkin Geliştirilen Model ve Deneysel Bulgular .....	37
5.1.1. Veri Seti ve Uygulama Detayları .....	37
5.1.2. Deneysel Bulgular.....	38
5.1.2.1. Model Performansı.....	38
5.2. Verimli Yeni Bir Evrişimli Sinir Ağı Tabanlı Model Kullanarak Beyin Tümörü Görüntülerinin Çoklu Sınıflandırmasına İlişkin Geliştirilen Model ve Deneysel Bulgular .....	40
5.2.1. Veri Seti ve Uygulama Detayları .....	40
5.2.2. Değerlendirme Metrikleri .....	43
5.2.3. Deneysel Bulgular.....	44
5.2.3.1. Modelin Sağlamlığını ve Genelleme Yeteneğini Doğrulama.....	45
5.2.4. Önerilen Modelin Kanonik ESA Mimarilerinden Farklılıkları .....	47
5.2.5. Ablasyon Çalışması .....	48
5.2.6. k-Katlı Çapraz Doğrulama .....	48
5.2.7. İlgili Çalışmalarla Karşılaştırma .....	49
5.3. Transformatör Tabanlı Derin Öğrenme Modellerinde Beyin MR Görüntü Sınıflandırmasının Başarısına Damıtma Tekniğinin Katkısına İlişkin Geliştirilen Model ve Deneysel Bulgular .....	50
5.3.1. Veri Seti ve Uygulama Detayları .....	50
5.3.2. Ön İşleme Adımları.....	51
5.3.3. Görüntü Dönüştürücü (ViT).....	51
5.3.4. Damıtılmış Veri Etkili Görüntü Dönüştürücü (Distilled Data-Efficient Image Transformer-DeiT) .....	52
5.3.5. Bert Görüntü Dönüştürücülerinin Ön Eğitimi (Bert Pre-Training of Image Transformers-BeiT).....	54
5.3.6. Deneysel Bulgular.....	56
5.3.6.1. Nicel Analiz .....	59
5.3.6.2. Zaman Performans Analizi.....	60
<b>6. TARTIŞMA, SONUÇ ve ÖNERİLER.....</b>	<b>61</b>
6.1. Tartışma .....	61
6.2. Sonuç ve Öneriler .....	62
<b>KAYNAKLAR.....</b>	<b>65</b>
<b>EKLER.....</b>	<b>71</b>
<b>ÖZ GEÇMİŞ</b>	

**ÖZET**  
**BEYİN TÜMÖRÜNÜN MANYETİK REZONANS GÖRÜNTÜLERİ ÜZERİNDEN**  
**DERİN ÖĞRENME YAKLAŞIMLARIYLA ERKEN TEŞHİSİ VE**  
**SINIFLANDIRILMASI**

Aynur SEVİNÇ

Doktora Tezi

**FIRAT ÜNİVERSİTESİ**

Sosyal Bilimleri Enstitüsü

**TEKNOLOJİ VE BİLGİ YÖNETİMİ ANA BİLİM DALI**

**Teknoloji ve Bilgi Yönetimi Programı**

Mart 2025, Sayfa: XIII + 72

Beyin tümörleri her yaştan bireyi etkileyebilen, en ölümcül tümör türlerinden biridir ve teşhis edilmezse yaşamı tehdit edici hale gelerek insan ömrünü kısaltabilir. Etkili tedavi için erken ve doğru teşhis esastır ve bilgisayar destekli tespit sistemleri, tıp uzmanlarının beyin tümörlerini tanımlamasına ve sınıflandırmasına yardımcı olmakta önemli bir rol oynar. Geleneksel yöntemler kullanılarak Manyetik Rezonans görüntülerinden beyin tümörlerinin tespiti, tıp doktorlarının uzmanlığını gerektiren zorlu ve hataya açık bir süreçtir. Yanlış veya eksik teşhis, insan hayatını tehdit eden ciddi sonuçlara yol açabilir. Bu zorlukların üstesinden gelmek için birçok araştırmacı Yapay Zekâ destekli otonom hastalık tespiti üzerinde çalışmaktadır. Bu kapsamda bu tez çalışması, Manyetik Rezonans görüntülerinden beyin tümörlerinin hızlı ve güvenilir bir şekilde teşhisi için etkili ve verimli derin öğrenme modelleri geliştirmeyi ve bu modellerin performansını değerlendirmeyi amaçlamaktadır.

Bu çalışmanın ilk aşamasında, Fırat Üniversitesi Girişimsel Olmayan Etik Kurul kararı, Elazığ Fethi Sekin Şehir Hastanesi Başhekimliği ile yapılan Bilimsel Araştırma İzinleri İşbirliği Protokolü ile verilen çalışma yürütme izni ve Elazığ İl Sağlık Müdürlüğü komisyon kararı sonucunda tez çalışmamız için veri seti oluşturulmuştur. Yapılan deneyler sonucunda çalışmanın yöntemi için derin öğrenme modelleri geliştirilmiş fakat veri setindeki Manyetik Rezonans görüntülerinin yeterli sayıda olmaması sebebiyle performans çıktılarının düşük olduğu gözlemlenmiştir. Çalışmanın seyri için hazır veri setleri araştırılmış ve kamuya açık literatürde yaygın olarak kullanılan, araştırmacılara önemli girdiler sunan platformlardan elde edilen üç farklı veri seti ile bu tez çalışması devam ettirilmiştir. Aynı uygulamalarla deneysel süreçler gerçekleştirilmiş ve üç ayrı başlık altında sunulmuştur. Bu bağlamda, ilk olarak iki ayrı Evrişimli Sinir Ağı altyapısı kullanılarak beyin görüntüleri sınıflandırılmıştır. Bu yaklaşımlardan biri, halen yaygın olarak kullanılan ve başarılı sınıflandırma çıktıları veren bir Derin Sinir Ağı modeli olan VGG-16'dır. Bu teknoloji ile eğitilen modelden %80 nihai doğruluk elde edilmiş ve görüntüler tümör var, tümör yok olarak sınıflandırılmıştır. Bir diğer derin öğrenme yaklaşımı olarak, sıfırdan verimli yeni bir Evrişimli Sinir Ağı tabanlı model geliştirilerek beyin tümörü görüntüleri yüksek doğrulukla sınıflandırılmıştır. Bu sınıflar; Glioma, Meningioma, Pituitary ve tümör yok olmak üzere dört ayrı kategoriyi içermektedir. Eğitim, doğrulama ve test süreçlerinde benzer parametrelerle deneyler yapılmış ve en uygun parametre ayarlamasıyla elde edilen sonuçlar, literatürdeki diğer çalışmalarla ayrıntılı olarak karşılaştırılmış ve aralarındaki farklar ortaya konulmuştur. Ayrıca çalışmanın sağlamlığını ve genellenebilirliğini ortaya koyan bir ablasyon çalışması yapılmış ve sonuçlar tablo halinde sunulmuştur. Çalışmada önerilen yeni Evrişimli Sinir Ağı tabanlı model, doğruluk değerlendirme metriğinde %99.76 oranında yüksek sınıflandırma sonucuna ulaşmış ve diğer değerlendirme metriklerinde de yüksek değerler elde edilmiştir. Ulaşılan sonuçlar, çalışmada önerilen modelin beyin tümörü tespitinde yüksek doğrulukla ve güvenle kullanılabileceğini ve diğer çalışma alanlarına ışık tutabileceğini göstermiştir.

Çalışmanın bir diğer ve en özgün yönü, transformatör tabanlı modellerin beyin tümörü sınıflandırma başarısına olan etkisinin incelenmesiydi. Transformatör tabanlı derin öğrenme modelleri esnek yapılarının sağladığı avantajlarla birçok hibrit modelde tercih edilmektedir. Ancak görüntü sınıflandırma alanında, az sayıda görüntü içeren veri kümelerinde bu modeller düşük başarı oranına sahiptir. Araştırmacılar bu probleme odaklanan bazı çalışmalar yapmış olsalar da, damıtma (distilasyon) tekniklerinin transformatör tabanlı modellerde sınıflandırma başarısına etkisi detaylı olarak incelenmemiştir. Bu kapsamda bu çalışmanın amacı, düşük veri miktarına sahip veri kümelerinde kullanılan transformatör tabanlı derin öğrenme modellerinin sınıflandırma başarısına damıtma tekniklerinin etkisinin araştırılmasıdır. Çalışmamızda, transformatör tabanlı ancak damıtma tekniklerini kullanmayan ViTx32 ve ViTx16 modelleri ile damıtma tekniklerini kullanan DeiT ve BeiT modelleri kullanılmıştır. Eğitim ve test süreçlerinde beyin Manyetik Rezonans görüntülerini içeren dört sınıflı bir veri kümesi tercih edilmiştir. Yapılan deneyler sonucunda, damıtma belirteçleri kullanan DeiT ve BeiT modellerinin, damıtma tekniği kullanılmayan ViTx16 modeline kıyasla sırasıyla %2.2 ve %1 başarı artışı sağladığı görülmüştür. Bununla birlikte, hasta olmayan bireylerin tespitinde damıtma tekniğinin kullanılmasının sınıflandırma performansını yaklaşık %4 oranında artırdığı görülmüştür. Ayrıca çalışmada modellerin eğitimde harcadığı zaman da detaylı olarak analiz edilmiştir. Çalışmamızdan elde edilen sonuçlar, damıtma tekniğinin kullanılmasının, düşük sayıda veriyle çalışırken transformatör tabanlı derin öğrenme modellerinin sınıflandırma başarısını önemli ölçüde artırdığını göstermektedir. Çalışmada elde edilen bulgulara dayanarak, özellikle tıp alanında sınırlı veri ile geliştirilen esnek modellerde, damıtma tekniği ile transformatör tabanlı modellerin kullanılması önerilmektedir.

**Anahtar Kelimeler:** Beyin tümörü, Manyetik rezonans görüntüleme, Evrişimli sinir ağı, VGG-16, ViT, DeiT, BeiT.

## **ABSTRACT**

### **Early Diagnosis and Classification of Brain Tumors Using Deep Learning Approaches on Magnetic Resonance Images**

Aynur SEVINÇ

Ph.D. Thesis

#### **FIRAT UNIVERSITY**

Graduate School of Social Sciences

#### **TECHNOLOGY and KNOWLEDGE MANAGEMENT**

#### **Technology and Knowledge Management Program**

March 2025, Page: XIII + 72

Brain tumors are among the most lethal types of tumors that can affect individuals of all ages. If left undiagnosed, they can become life-threatening and significantly shorten a person's lifespan. Early and accurate diagnosis is essential for effective treatment, and computer-aided detection systems play a crucial role in assisting medical professionals in identifying and classifying brain tumors. Detecting brain tumors from Magnetic Resonance Imaging (MRI) scans using traditional methods is a challenging and error-prone process that requires the expertise of medical doctors. Incorrect or incomplete diagnoses can lead to severe consequences that endanger human life. To overcome these challenges, many researchers are working on artificial intelligence-assisted autonomous disease detection. In this context, this thesis aims to develop effective and efficient deep learning models for the rapid and reliable diagnosis of brain tumors from MRI scans and to evaluate the performance of these models.

In the initial phase of this study, a dataset was created for the thesis research based on the decision of the Firat University Non-Interventional Ethics Committee, the Scientific Research Permissions Cooperation Protocol with the Elazığ Fethi Sekin City Hospital Directorate, and the commission decision of the Elazığ Provincial Health Directorate. Experiments were conducted, and deep learning models were developed for the study's methodology. However, it was observed that the performance outcomes were low due to the insufficient number of Magnetic Resonance Imaging (MRI) scans in the dataset. To address this limitation, publicly available datasets were explored, and the study proceeded with three different datasets obtained from widely used platforms in the literature, which provide valuable inputs for researchers. Separate experimental processes were carried out and presented under three different sections. In this context, brain image classification was first performed using two different Convolutional Neural Network (CNN) architectures. One of these approaches was VGG-16, a widely used Deep Neural Network model known for its successful classification performance. The model trained with this technology achieved a final accuracy of 80%, classifying images as either "tumor present" or "no tumor". As another deep learning approach, a new and efficient CNN-based model was developed from scratch to classify brain tumor images with high accuracy. This classification included four distinct categories: Glioma, Meningioma, Pituitary, and No tumor. Experiments were conducted during the training, validation, and testing phases using similar parameters, and the results obtained with the optimal parameter tuning were thoroughly compared with other studies in the literature, highlighting the differences. Additionally, an ablation study was performed to demonstrate the robustness and generalizability of the proposed approach, with the results presented in tabular format. The newly proposed Convolutional Neural Network-based model achieved a high classification accuracy of 99.76% in the accuracy evaluation metric and also obtained high values in other evaluation metrics. These results indicate that the proposed model

can be used with high accuracy and reliability in brain tumor detection and may provide valuable insights for other research areas.

Another and perhaps the most original aspect of this study was the investigation of the impact of transformer-based models on brain tumor classification performance. Transformer-based deep learning models are commonly preferred in many hybrid architectures due to the advantages provided by their flexible structures. However, in the field of image classification, these models tend to exhibit low performance when used with datasets containing a limited number of images. Although some studies have focused on this issue, the effect of distillation techniques on the classification performance of transformer-based models has not been thoroughly explored. Within this context, the aim of this study is to examine the effect of distillation techniques on the classification performance of transformer-based deep learning models used with datasets of limited size. In our study, transformer-based models that do not employ distillation techniques—ViTx32 and ViTx16—were used alongside distillation-based models—DeiT and BeiT. A four-class dataset comprising brain Magnetic Resonance (MR) images was selected for the training and testing processes. As a result of the experiments, it was observed that the distillation-based models DeiT and BeiT outperformed the ViTx16 model, which does not utilize distillation, by 2.2% and 1%, respectively. Additionally, it was found that the use of distillation techniques increased classification performance by approximately 4% in detecting non-tumorous individuals. Furthermore, the training time of each model was analyzed in detail. The results obtained from our study indicate that applying distillation techniques significantly enhances the classification performance of transformer-based deep learning models, especially when working with limited data. Based on the findings of this study, the use of distillation-enhanced transformer-based models is recommended, particularly in the development of flexible models in the medical domain where data availability is often limited.

**Keywords:** Brain tumor, Magnetic resonance imaging, Convolutional neural network, VGG-16, ViT, DeiT, BeiT.

## ŞEKİLLER LİSTESİ

Şekil 1.	Beyin dokusunda oluşan tümör (Birincil beyin tümörü) (Mayoclinic, 2024) .....	8
Şekil 2.	Beyin tümörünün gruplandırılması .....	9
Şekil 3.	Beyin tümörünün derecelendirme kriterleri .....	9
Şekil 4.	Astrositom tümör tipi .....	11
Şekil 5.	Glioblastoma tümör tipi .....	11
Şekil 6.	Meningioma tümör tipi .....	12
Şekil 7.	Pituitary tümör tipi .....	13
Şekil 8.	Beyin tümörü görüntüleme yöntemleri (Dere (2017)'den uyarlanmıştır) .....	14
Şekil 9.	Yapay zekâ unsurları .....	17
Şekil 10.	Sinir hücresi modeli ve sinir hücresi bileşenleri .....	19
Şekil 11.	Yapay sinir hücresi .....	19
Şekil 12.	Sigmoid fonksiyonu değer grafiği .....	21
Şekil 13.	Softmax aktivasyon fonksiyonu değer grafiği .....	21
Şekil 14.	ReLU ve dReLU aktivasyon fonksiyonu değer grafikleri .....	22
Şekil 15.	Yapay sinir ağları katmanları .....	23
Şekil 16.	Evrişimli sinir ağı modeli .....	27
Şekil 17.	VGG-16 modeli .....	29
Şekil 18.	Vision Transformer (ViT) model diyagramı .....	30
Şekil 19.	Veri seti-1'den görsel örnekler ve sayıları .....	31
Şekil 20.	Yeni klasör hiyerarşisindeki dokuz dizin .....	32
Şekil 21.	Veri seti-2'nin bölünme oranı .....	32
Şekil 22.	Veri seti-2'den görsel örnekler ve sayıları .....	32
Şekil 23.	Veri seti-2'de yer alan tümör tiplerinin yüzdelik dağılımı .....	33
Şekil 24.	Veri seti-3'ten görsel örnekler ve sayıları .....	33
Şekil 25.	Yeni klasör hiyerarşisindeki dizinler .....	34
Şekil 26.	Görüntülerin dağılım oranları .....	35
Şekil 27.	Normalleştirme adımları .....	35
Şekil 28.	Artırılmış görüntüler .....	36
Şekil 29.	Kırpılan ve 224×224 olarak yeniden boyutlandırılan görüntü örnekleri .....	36
Şekil 30.	Önerilen yöntem için teşhis süreci .....	37
Şekil 31.	Karışıklık matrisi .....	39
Şekil 32.	Yanlış ve doğru sınıflandırılan görüntü örnekleri .....	40
Şekil 33.	Önerilen ESA modeli .....	41
Şekil 34.	Kütüphaneleri içe aktarma .....	44
Şekil 35.	Eğitim ve test eğrilik grafikleri .....	46
Şekil 36.	Modelin karışıklık matrisi .....	47
Şekil 37.	Görüntü dönüştürücü (ViT) model diyagramı .....	52
Şekil 38.	Damıtılmış veri etkili görüntü dönüştürücü (DeiT) model diyagramı .....	53
Şekil 39.	BERT görüntü dönüştürücülerinin ön eğitimi (BeiT) model diyagramı .....	55
Şekil 40.	Transformatör tabanlı görüntü sınıflandırma modelleri çapraz entropi kayıp grafikleri (a) ViTx16 (b) ViTx32 (c) DeiT (d) BeiT .....	57

## TABLÖLAR LİSTESİ

<b>Tablo 1.</b>	Önerilen ESA, VGG-16 modelinin özet bilgileri.....	38
<b>Tablo 2.</b>	ESA modelimizde kullanılan hiper-parametre değerleri.....	42
<b>Tablo 3.</b>	Karışıklık matrisi .....	43
<b>Tablo 4.</b>	Önerilen ESA modelinin performans ölçütleri .....	44
<b>Tablo 5.</b>	Farklı veri kümelerindeki performans doğruluk değerleri .....	45
<b>Tablo 6.</b>	Farklı sınıflandırıcıların doğruluk oranları .....	45
<b>Tablo 7.</b>	ESA modelde farklı hiper parametrelerin kullanılması .....	48
<b>Tablo 8.</b>	k-Katlı çapraz doğrulama sonuçları .....	48
<b>Tablo 9.</b>	Veri seti 3'e dayalı beyin tümörleri üzerine yapılan çalışmaların karşılaştırmalı incelemesi .....	49
<b>Tablo 10.</b>	Derin öğrenme modellerinde kullanılan hiper-parametreler.....	56
<b>Tablo 11.</b>	Transformatör tabanlı ancak bilgi tabanlı damıtma olmadan derin öğrenme modellerinden elde edilen test görüntüleri için sınıflandırma sonuçları.....	58
<b>Tablo 12.</b>	Bilgi tabanlı damıtma ile transformatör tabanlı derin öğrenme modellerinden elde edilen test görüntüleri için sınıflandırma sonuçları.....	58
<b>Tablo 13.</b>	Test görüntüleri üzerinde elde edilen tüm sınıflar için farklı değerlendirme metrikleriyle ayrı sınıflandırma sonuçları ve hesaplanan ağırlıklı ortalama doğruluk değeri .....	59
<b>Tablo 14.</b>	Aynı geliştirme ortamında gerçekleştirilen eğitimlerin zaman ortalamaları .....	60

## EKLER LİSTESİ

<b>Ek- 1:</b> Etik Kurul Onayı.....	71
<b>Ek- 2:</b> T.C Sağlık Bakanlığı Elazığ İl Sağlık Müdürlüğü Komisyon Kararı .....	72



## SİMGELER

$X_i$	: Girdiler
$W_i$	: Ağırlıklar
$b$	: Bias
$y$	: Çıktı
$\vec{z}_i$	: Giriş vektörü
$z_i$	: Giriş vektörü elemanları
$K$	: Sınıf sayısı
$e$	: Euler sayısı
$\psi$	: Softmax
$\mathcal{L}_{CE}$	: Çapraz entropi kaybı
$Z_s$	: Öğrencinin lojitleri
$y$	: Temel gerçek
$\mathcal{Y}_t$	: Öğretmenin tahmin ettiği etiketler
$k$	: Katman sayısı

## KISALTMALAR

ADE	: Ortalama Farksal Gelişim (Average Differential Evolution)
ASCO	: Amerikan Klinik Onkoloji Derneği (American Society of Clinical Oncology)
BeiT	: Bert Görüntü Dönüştürücülerinin Ön Eğitimi (Bert Pre-Training of Image Transformers)
BT	: Bilgisayarlı Tomografi (Computerized Tomography)
CNN	: Evrişimsel Sinir Ağları (Convolutional Neural Networks)
DeiT	: Veri Etkili Görüntü Dönüştürücü (Data-Efficient Image Transformer)
DİA	: Derin İnanç Ağı
DSA	: Derin Sinir Ağları (Deep Neural Network)
DÖ	: Derin Öğrenme (Deep Learning)
DSÖ	: Dünya Sağlık Örgütü
ESA	: Evrişimli Sinir Ağı
FN	: Yanlış Negatif (False Negatives)
FP	: Yanlış Pozitif (False Positives)
k-NN	: k En Yakın Komşu (k-Nearest Neighbors)
LSTM	: Uzun-Kısa Süreli Bellek (Long-Short Term Memory)
MDM	: Maskelenmiş Dil Modelleme
MGM	: Maskelenmiş Görüntü Modelleme
MÖ	: Makine Öğrenmesi (Machine Learning)
MRA	: Manyetik Rezonans Anjiyografi
MRG	: Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging)
MRS	: Manyetik Rezonans Spektroskopi
MSS	: Merkezi Sinir Sistemi
NG	: Net Girdi
NLP	: Doğal Dil İşleme (Neuro Linguistic Programming)
PET	: Pozitron Emisyon Tomografisi
ReLU	: Rektifiye Lineer Birim (Rectified Linear Unit)
RFA	: Radyofrekans Ablasyon
RPN	: Bölge Öneri Ağı (Region Proposal Network)
SGD	: Stokastik Gradyan İnişi (Stochastic Gradient Descent)
DVM	: Destek Vektör Makineleri (Support Vector Machine)
TN	: Doğru Negatif (True Negative)
TÖ	: Transfer Öğrenme
TP	: Doğru Pozitif (True Positives)
TSA	: Tekrarlayan Sinir Ağı
ViT	: Görüntü Dönüştürücü (Vision Transformer)
VQ-VAE	: Vector Quantized Variational Autoencoder
WAcc	: Ağırlıklandırılmış Ortalama Doğruluk
XAI	: Açıklanabilir Yapay Zekâ (Explainable Artificial Intelligence)
YSA	: Yapay Sinir Ağı (Artificial Neural Network)
YZ	: Yapay Zekâ (Artificial Intelligence)

## 1. GİRİŞ

Beyindeki kontrolsüz hücre büyümesiyle karakterize edilen beyin tümörleri, bu tümör tipinin insanlarda görülme sıklığı ve hayati önemi bakımından modern tıbbın önemli bir ilgi alanıdır. Her yaştan ve cinsiyetten insanı etkileyebilen beyin tümörü, agresif ve heterojen bir yapıya sahip olmasıyla tedavisi en zor ve en ölümcül anormalliklerden biri olarak kabul edilir. Beyin tümörlerinin ileri aşamaya gelmemesi için mümkün olan en kısa sürede bulunması gerekir. Beyin tümörleri, yapılarına göre birincil ve ikincil tümörler olmak üzere iki türe ayrılır (Bauer vd., 2013). Beynin içinde ortaya çıkan tümörler birincil, vücudun başka bir bölgesinde ortaya çıkıp daha sonra beyne doğru ilerleyen tümör tipleri ise ikincil tümörler olarak kabul edilir (Swapnil ve Girish, 2020). Yetişkinlerde Merkezi Sinir Sisteminde (MSS) en sık rastlanan en ölümcül birincil beyin tümörü tipi gliomalardır. Bu tümör beyin destekleyici dokusu olarak bilinen glial hücreler üzerinde oluşur ve çevre dokulara yayılır. Bu tümör tipi kendi içinde yüksek dereceli ve düşük dereceli olarak derecelendirilmektedir. Yüksek dereceli gliomaların 5 yıllık hayatta sağkalım oranı ise %5'in altında seyretmektedir (Miller vd., 2021).

Beyin tümörlerinin erken teşhisi ve doğru tedavinin uygulanması hasta ömrünü uzatmada kritik öneme sahiptir. Beyin tümörleri deneyimli radyolog hekimler tarafından Bilgisayarlı Tomografi (BT), Manyetik Rezonans Görüntüleme (MRG) ve Pozitron Emisyon Tomografisi (PET) taramaları ile teşhis edilebilmektedir (Rabby vd., 2024). MRG'nin diğer görüntüleme tekniklerine göre bazı avantajları vardır. Tümörün teşhisi için beynin üç boyutlu görüntüsünü veren MRG taramaları sağlık sektöründe tıbbi görüntüleme teknolojisine önemli katkı sağlamıştır. MRG, insan vücudunda gelişen karmaşık yapıları anlamamıza ve görselleştirmemize olanak tanıyan bir teknolojidir. Bu modern teknoloji geleneksel görüntüleme yöntemlerini geride bırakır ve beyin sorunlarını tam olarak belirleyebilir (Nazir vd., 2024). Yüksek çözünürlüğü ve netliği ile tümörün yerini, boyutunu, yapısını doğru biçimde tespit ederek tümörün varlığını çıktı görüntülerine başarılı biçimde yansıtabilmesi ile görüntülemedeki en doğru yöntem olduğunu kanıtlamıştır.

Günümüzde tıbbın neredeyse her alanında Yapay Zekâdan (YZ) faydalanılmaktadır. Tıpta YZ'nin kullanıldığı en önemli alanlardan biri, beyin tümörlerinin doğru teşhis edilmesi ve iyi/kötü huylu olmak üzere çeşitli şekillerde kategorize edilmesidir (Akyel ve Akdemir, 2020). Hastalığın teşhis sürecinde kullanılan verilere uygun derin öğrenme modelinin tercih edilmesi, hastalığa erken tanı koyma başarısını artırmaktadır. YZ teknolojilerinden olan Makine Öğrenmesi (MÖ) alanında geliştirilen Derin Öğrenme (DÖ) algoritmalarının kullanılarak otomatik sınıflandırma tekniklerinin uygulanması, manuel sınıflandırmadan sürekli olarak daha yüksek doğruluk göstermiştir. Bu tür yenilikçi yöntemler, otomatik medikal karar verme sistemlerinin geliştirilmesi için önemlidir, çünkü manuel süreçler hem daha maliyetli hem de yoğun iş gücü gerektirirken, insan hatalarına da açıktır (Karabulut, 2016). Bu nedenle, Evrişimli Sinir Ağı (ESA), Yapay Sinir Ağı (YSA) ve Transfer Öğrenme (TÖ) gibi derin öğrenme algoritmaları kullanılarak algılama ve sınıflandırma yapan bir sistem önermek hekimlere yardımcı olacaktır.

Görüntü işlemede dönüştürücü modellerin kullanımı son yıllarda önemli bir çalışma alanıdır. Geleneksel derin öğrenme modellerinde kullanılan ESA'larla birlikte son araştırmalarda doğal dil işlemede yüksek başarı elde eden dönüştürücü tabanlı modeller kullanılmaya başlanmıştır. Ancak dönüştürücü modellerin yüksek başarı elde edebilmesi için çok sayıda görüntü ile eğitilmesi gerekmektedir. Özellikle tıbbi görüntüleme alanında çok sayıda veri içeren veri kümeleri bulmak zordur. Uzayan veri kümesi toplama sürecinin salgın hastalıklar sırasında DÖ modellerinin

kullanımını geciktiren önemli bir değişken olduğu gözlemlenmiştir (Tee vd., 2020; Luo vd., 2020). Araştırmacılar, az sayıda görüntü içeren veri kümeleriyle yüksek başarı elde edebilen dönüştürücü tabanlı modeller üzerinde çalışmaktadır.

Görüntü Dönüştürücü Modeli (ViT), sınıflandırma ve segmentasyon gibi zorlu görevlerde yüksek başarı elde etmiştir. Singh ve arkadaşları (2024), toplamda 5863 görüntü içeren göğüs röntgeni görüntüleri üzerinde ViT modeliyle zatürre ve normal olmak üzere iki sınıfa sahip bir veri seti üzerinde çalışmış, yüksek veri sayısı ve düşük sınıf sayısı avantajıyla zatürreyi %97.61 doğrulukla sınıflandırmışlardır. Tıbbi görüntülerde görüntü dönüştürücü modelini kullanan bir diğer çalışma Xin ve arkadaşları (2022) tarafından yürütülmüştür. Toplamda 10015 cilt kanseri görüntüsü içeren HAM10000 veri seti, cilt kanseri görüntülerini sınıflandırmak için kullanılmış ve araştırmacılar ViT modeliyle cilt kanseri görüntülerini sınıflandırmada %94.3 başarı elde etmişlerdir. Transformatör tabanlı modellerin düşük sayıda görüntü içeren veri kümelerinde de yüksek başarıya ulaşması için araştırmalara devam edilmelidir. Bu probleme çözüm önerisi olarak, Veri Etkili Görüntü Dönüştürücü Modeli (DeiT), bir damıtma belirteci kullanan dönüştürücü tabanlı bir modeldir. Bu model, veri damıtma belirteçlerine sahip modelin geliştirilmiş bir versiyonudur. DeiT modeli yeni bir derin öğrenme modeli olmasına rağmen, literatürde birçok alanda kullanılmıştır. Damıtma yöntemlerini kullanarak dönüştürücü tabanlı modellerin performansını iyileştirmeye odaklanan başka modeller de vardır. Bu modellerden biri de BeiT modelidir. BeiT, bilgi damıtma yöntemlerini ve maskelenmiş görüntü yamalarını kullanır. BeiT modeli yalnızca tıbbi görüntülerde değil aynı zamanda Elektrokardiyografi (EKG) sinyallerinde de sınıflandırma görevlerinde kullanılmıştır. Jain ve Menon (2023), EKG sinyalleri ve BeiT modelini kullanarak anormal kalp ritminin tespit edilmesi üzerine çalışmıştır.

Literatürde incelenen çalışmalardan gözlemlendiği üzere, tıbbi görüntü analizinde transformatör tabanlı modellerin potansiyeli hızla artmasına rağmen, yöntemlerin beyin MR görüntülerindeki etkinliği henüz karşılaştırmalı olarak gösterilmemiştir. Özellikle, damıtma yöntemlerinin tıbbi görüntülerin analizinde hastalık teşhisinin performansına etkisi net bir şekilde araştırılmamıştır. Bu tez çalışması, tıbbi görüntülerden hastalık teşhisinde transformatör tabanlı modellerin başarısını değerlendiren ilk çalışmalardan biri olmayı hedeflemektedir. Bu kapsamda ViT, DeiT ve BeiT modelleri eğitilmiş ve sonuçlar ayrıntılı olarak analiz edilmiştir. Damıtma belirteçlerinin kullanımının performans iyileştirmesi üzerindeki etkisi birden fazla açıdan incelenmiştir.

Bu çalışmada, MR görüntülerinden farklı DÖ modelleri ile beyin tümörü bölgelerinin otomatik olarak tespit edilmesi ve yüksek doğrulukla sınıflandırılması amaçlanmıştır. Tespit edilen tümörler; glioma, meningioma, pituitary ve tümör yok olarak sınıflandırılmıştır. Araştırmada etik kurul alınarak Elazığ Fethi Sekin Şehir Hastanesi'nden temin edilen MR görüntülerinden oluşturulan veri seti kullanılmış fakat alınan verilerin yetersiz sayıda olması ve yapılan deneyler sonucunda alınan performans çıktılarının düşük değerlerde olması sebebiyle beyin tümörü çalışmaları için hazır veri setleri sunan Kaggle platformundan elde edilen üç farklı veri seti ile çalışma devam ettirilmiştir. Önerdiğimiz derin öğrenme modelleri, veri setlerimiz ile eğitilmiş, deneysel sonuçlar gözlemlenmiş, yorumlanmış ve karşılaştırmalı olarak sunulmuştur. Araştırma kapsamında çalışmanın bu bölümünde araştırmanın amacı, araştırmanın önemi, zorluklar ve sınırlılıklar ile literatür özeti yer almaktadır.

## 1.1. Araştırmanın Amacı

Özellik çıkarma yeteneği ve bu özelliklerin teşhis ve sınıflandırma sürecinde kullanımını sağlayan DÖ algoritmaları tespit ve sınıflandırma probleminin doğruluğunu artıran stratejilerdir. Özellikle yüksek performans başarısı gösteren ESA, tümörün tespiti ve sınıflandırmasında dikkate değer sonuçlar üreterek son yıllarda devrim yaratmıştır. Çalışmamızın temel amacı, derin öğrenme yaklaşımlarını kullanarak beyin tümörünü yüksek doğrulukla tespit etmek, tanımlamak, sınıflandırmak ve geliştirilen modelin performansını değerlendirmektir. Ayrıca düşük veri miktarına sahip veri kümelerinde, transformatör tabanlı derin öğrenme modellerinin sınıflandırma başarısına distilasyon (damıtma) tekniklerinin etkisinin araştırılması amaçlanmıştır. Tıp alanında sınırlı veri ile geliştirilen bu esnek model yaklaşımı literatürdeki ilk çalışma olmayı hedeflemektedir.

## 1.2. Araştırmanın Önemi

Normal doku ve beyin tümörü hücreleri arasında görünüşte iyi bir benzerlik vardır, bu nedenle tümör bölgelerinin bölütlenmesi zor bir iş haline gelir. Bu durum hastanın uygun tıbbi tedavisini etkileyebilir. Bu nedenle, oldukça hassas bir otomatik tümör tespit ve sınıflandırma yönteminin geliştirilmesi için bir zorunluluk vardır. MÖ'ye dayalı derin yöntemler bu süreci daha hızlı ve kontrollü olarak düşük hata oranında gerçekleştirmeye imkan sunmaktadır. Bu noktada çalışmanın DÖ yaklaşımlarına dayalı deney sonuçlarının, medikal karar vermeyi destekleyecek yönde katkı sağlayacağı düşünülmektedir.

Beyin tümörlerinin erken ve doğru teşhisi, hastaların tedavi sürecinde kritik bir aşamadır; çünkü doğru sınıflandırma, uygulanacak tedavi yönteminin belirlenmesinde doğrudan etkili olur. ESA tabanlı modeller, MRG gibi tıbbi görüntülerden karmaşık özellikleri otomatik olarak çıkararak yüksek doğruluk oranlarıyla benign (iyi huylu) ve malign (kötü huylu) tümör ayrımı yapabilmekte, doktorlara hızlı ve güvenilir bir yardımcı araç sunabilmektedir. Bu alanda yapılan araştırmalar, model performansını artırmaya, veri çeşitliliğini genişletmeye ve klinik uygulamalara entegrasyon sağlamaya odaklanarak tıbbi teşhislerin kalitesini yükseltmekte ve hasta sağlığına önemli katkılar sunmaktadır. Dolayısıyla, ESA'lar ile beyin tümörü sınıflandırması konusundaki çalışmalar, hem YZ hem de tıp alanında çığır açıcı bir öneme sahiptir.

Doğru teşhis ve tedavi sürecinin hızlandırılması amacıyla yapılan tıbbi görüntü araştırmalarını iyileştirmek için daha önce önerilen yöntemlerin geliştirilerek doğruluk performansının artırılması oldukça önem arz etmektedir. Bu kapsamda bu çalışmada geliştirilen ESA modeli, literatürdeki birçok beyin tümörü sınıflandırma çalışmasını geride bırakarak teşhis ve sınıflandırma doğruluğunu önemli ölçüde artırmaktadır. Geliştirilen sistem diğer ilgili tüm çalışmalar içinde en iyi sınıflandırma doğruluğunu elde eden çalışmalardan biridir. Kanonik ESA'lardan ayrılan yönleriyle sıfırdan yeni etkin bir ESA model geliştirilmiştir. Önerilen modelin klinisyenlere tümörün türünü tahmin etme ve hastalara en uygun tedavi yönteminin sağlanması noktasında yardımcı olacağı düşünülmektedir.

ViT modeli, görüntü işleme alanında sunduğu yenilikçi yaklaşım sayesinde beyin tümörü sınıflandırması gibi kritik tıbbi uygulamalarda giderek daha fazla önem kazanmaktadır. ViT'in yüksek genel performansı ve esnek mimarisi yüksek doğruluk oranlarına ulaşmasını sağlarken, doktorlara hızlı ve güvenilir bir karar destek sistemi sunar. Bu nedenle ViT tabanlı araştırmalar, tıbbi görüntü analizi alanında yenilikçi çözümler sunarak, beyin tümörü teşhisinde doğruluk, hız ve güvenilirlik açısından büyük bir potansiyele sahiptir. Bu tez çalışması, tıbbi görüntülerden hastalık teşhisinde transformatör tabanlı modellerin başarısını farklı yönlerden değerlendiren ilk

çalışmalardan biridir ve damıtma belirteçlerinin kullanımının beyin MR görüntü sınıflandırmasının performansını iyileştirip iyileştirmediğini incelemektedir. Çalışmamızın literatüre en önemli katkısı, transformatör tabanlı modellerde damıtma tekniğinin kullanımının küçük veri kümelerindeki sınıflandırma başarısına etkisini araştırmaktır. Küçük veri kümeleri üzerinde yaptığımız çalışma, özellikle salgın hastalıklar veya büyük veri kümeleri oluşturmanın zor olduğu diğer hastalıklar gibi özel durumlarda tıp alanında çalışanlara rehberlik edecektir.

### 1.3. Zorluklar ve Sınırlılıklar

- Araştırma, bu çalışma kapsamında kullanılan MR görüntüleri ile sınırlıdır.
- Derin öğrenme sistemlerinin hata yapma eğilimleri çalışmanın bir diğer sınırlılığıdır.
- ESA modelinin beyin tümörü tespitinde yüksek seviyelerde doğruluk sağlamasının yanında çekirdek tümör olarak adlandırılan tümörlerin tam olarak tespit edilememesi bu çalışmanın bir sınırlılığıdır.
- Veri setini oluşturan görüntülerde; tümör yapısındaki heterojenlik, tümörlerde sınıflar arası değişkenlik, mekanik işlemde kaynaklı fiziksel aksaklıklar (özne görüntüsü alma sırasında hareket etme vs.), çok sınıflı sınıflandırma gibi performans düşürücü faktörler ortaya çıkabilir.
- Derin mimariler çoğunlukla yüksek doğruluk gösterir, ancak öğrenmeleri gereken çok sayıda parametre nedeniyle yakınsama hızları düşük olabilmektedir.
- ViT modelinin performans başarısını tam olarak gerçekleştirebilmesi için büyük miktarda veriyle çalışmasının gerekliliği bu çalışmanın bir diğer sınırlılığıdır.

### 1.4. Literatür Özeti

Literatürde yer alan çalışmalara bakıldığında, beyin tümörünün teşhis ve sınıflandırılması ile segmentasyonuna yönelik başarılı deneysel sonuçlar üreten derin öğrenme çalışmalarının gerçekleştirildiği görülmüştür. Özellikle, geliştirilen derin ESA ağlarının beyin tümörünü otomatik olarak tespit etme ve doğru sınıflandırma oranlarının yüksek olduğu belirlenmiştir. Bunun yanında ViT modelinin tıbbi görüntü analizi ve özellikle beyin görüntülerinin sınıflandırılması gibi çalışmalarda kullanımı giderek artmaktadır. Bu çalışmaların bazıları bu kısımda özetlenmektedir. Derin öğrenme yaklaşımıyla beyin tümörünün tespit ve sınıflandırılması üzerine yapılan güncel çalışmalar incelenmiş ve aşağıda sırasıyla sunulmuştur.

*Kumar, Prasad ve Metan (2022)*, beyin tümörü tespit ve sınıflandırılması üzerine gerçekleştirdikleri çalışmalarında ESA ve Transfer öğrenme taktiklerini kullanan ResNet-152 Transfer Öğrenme modeli ile Derin Evrişimli Sinir Ağı önermişlerdir. Yapılan çalışmada, tümör tespitinde düşük hata oranıyla yüksek doğruluk elde edilmiştir. *Bhanothu, Kamalakannan ve Rajamanickam (2020)*, tümörü tespit etmek ve oluşum alanını Bölge Öneri Ağı ile işaretlemek için daha hızlı R-CNN derin öğrenme algoritmasını önermişlerdir. Önerilen algoritma, hem Bölge Öneri Ağı hem de sınıflandırıcı ağ için temel katman olarak VGG-16 modelini kullanır. Algoritmanın tespit ve sınıflandırma sonuçları, glioma için %75.18, meningiom için %89.45 ve hipofiz tümörü için %68.18 ortalama doğruluk sağladığı görülmüştür. Bir performans ölçüsü olarak, algoritma tüm sınıflar için ortalama %77.60'lık bir ortalama hassasiyet elde etmiştir. *Çınar ve Yıldırım (2020)*, teşhis işlemi için derin öğrenme ağlarından biri olan ESA ve ESA modellerinden Resnet50'yi kullanmıştır. Resnet50 modelinin son beş katmanı kaldırılmış ve sekiz yeni katman eklenmiştir. Bu

model ile %97.2 doğruluk değeri elde edilmiştir. Ayrıca AlexNet, ResNet50, DenseNet201, InceptionV3 ve GoogleNet modelleri uygulanmıştır. Tüm bu modellerden en yüksek performansla geliştirilen model beyin tümörü görüntülerini sınıflandırmıştır.

*Vankdothu, Hameed ve Fatima (2022)*, MR görüntülerini kullanarak beyin tümörlerini saptamak için derin öğrenmeye dayalı bir IoT hesaplama sistemi geliştirmişlerdir. Çalışma bir ESA'yı bir Uzun-Kısa Süreli Bellek (LSTM) ile birleştirmeyi önerir. Modelin performansı 3264 MR görüntüsü içeren Kaggle platformundan alınan veri seti ile denenmiştir. Deneysel bulgular sonucunda modelin %92 doğruluk gösterdiği belirlenmiştir. *Patil ve Kirange (2023)*, önerdikleri modelde, T1C modalite MRG ile Sığ Konvolüsyonel Sinir Ağı (SCNN) ve VGG-16 ağı tasarlayarak kayıp ve doğruluğu incelemiştir. Topluluk derin ESA modelinden (EDCNN) elde edilen deneysel sonuçlar, derin öğrenme modelinin birleştirilmesinin çok sınıflı sınıflandırma probleminin doğruluğunu geliştirdiğini göstermiştir. Geliştirilen model %97.77'ye kadar sınıflandırma doğruluğu vermiştir. *Aslan (2022)*, derin öğrenme tabanlı beyin tümörü tespiti çalışmasında, MR görüntüleri kullanarak beyin tümörünün tespit edilmesi amacıyla MobilNetV2 derin ağ modeliyle birlikte k en yakın komşu (k-NN) algoritmasını kullanmıştır. Önerilen yöntem beyin tümörlerinin tespit edilmesinde k-NN sınıflandırıcıda %96.44 doğruluk oranı elde etmiştir. *Deepak ve Ameer (2019)*, TÖ metoduyla derin ESA özelliklerini kullanarak beyin tümörünü sınıflandırmışlardır. Çalışma üç önemli beyin tümörü tipini (glioma, menenjiyom, hipofiz) ayırt etmek için üç sınıflı bir sınıflandırma problemine odaklanır. MR görüntülerinden özellik çıkarımı için önceden eğitilmiş bir GoogleNet teknolojisi kullanılmıştır. Figshare'den alınan MR veri seti üzerinde gerçekleştirilen çalışmada önerilen sistem %98 oranında sınıflandırma doğruluğu göstermiştir. Çalışmada kullanılan diğer performans ölçütleri; kesinlik, F-skoru, eğrinin altındaki alan (AUC), özgüllük ve hatırlamadır.

*Rabby ve arkadaşları (2024)*, 2D MRG'den beyin tümörü segmentasyonu, sınıflandırması ve lokalizasyonu için uçtan uca çok görevli derin öğrenme mimarisinin potansiyelini göstererek doğru ve etkili sonuçlar sunmayı hedeflemişlerdir. Test edilen çeşitli modeller arasında, InceptionV3 ile birlikte U-net, 0.86'lık en yüksek zar puanına ulaşmış ve ek olarak, Küresel Ortalama Havuzlama katmanını bir tanesi hariç eğitilemeyen katmanlarla birleştirilerek VGG-16 modeli değiştirilmiştir. Bu da eğitim süresini kısaltmış, hassasiyet ve geri çağırma oranlarını iyileştirmiştir. Model ayrıca, belirsiz tümör sınırları, birden fazla tümörün varlığı ve MRG'de kistik veya nekrotik bileşenlerden kaçınma gibi zorlu senaryolarda tümörleri tespit etmede de değerli olduğunu kanıtlamıştır. *Alzahrani ve Kahtani (2024)* çalışmalarında, özellikle MRG yoluyla birden fazla beyin tümörü sınıfının tanımlanması için özel olarak tasarlanmış, dönüştürücü kodlayıcı modelleri içinde üçlü dikkat mekanizması kullanan yenilikçi bir bilgi damıtma çerçevesini tanıtmışlardır. Çalışma, karmaşık tıbbi görüntü analizi görevlerinde bilgi damıtmanın etkinliğini doğrulamakla kalmıyor, aynı zamanda gerçek dünyadaki klinik uygulamalara en son YZ tekniklerinin entegre edilmesi için umut verici bir yol da sunmaktadır. *Nazir ve arkadaşları (2024)*, çalışmalarında üç gelişmiş Açıklanabilir Yapay Zekâ (XAI) tekniğiyle desteklenen özelleştirilmiş bir ESA modeli kullanmıştır. Önerilen model, %100'lük dikkate değer bir eğitim doğruluğu ve %98.67'lik bir doğrulama doğruluğu elde etmiştir. *Goceri (2025)*, MRG'lerden glioma derecelendirmesi ve beyin tümörü sınıflandırması için ESA ve dönüştürücü bloklar içeren verimli bir ağ tasarlamıştır. Önerilen yaklaşım, glioma derecelendirmesinde %99.21 ve beyin tümörü sınıflandırmasında %98.66'lık yüksek bir doğruluk elde etmiştir.

*Ferdous ve arkadaşları (2023)*, DeiT modeliyle bir beyin MR görüntüleri veri kümesini eğitmiş ve toplamda 2040 görüntü içeren veri kümesinde %93.69 doğruluk elde etmişlerdir. *Rajesh*

ve arkadaşları (2024), BeiT modelini kullanarak Parkinson hastalığını tespit etmeye çalışmış ve eğitimden sonra mimarinin %90 başarı elde ettiği gözlemlenmiştir. Bir başka çalışma, görüntü dönüştürücüler ve Alzheimer hastalığı üzerine *Shin ve arkadaşları (2023)* tarafından yürütülmüştür. Araştırmacılar, FBB görüntü veri setindeki üç sınıftan toplam 716 görüntü üzerinde çalışmışlardır. Eğitim ve testi ayrı ayrı ViT ve VGG-19 modelleriyle gerçekleştirmişlerdir. VGG-19 modeliyle %66.67 ve ViT modeliyle de %56.67 başarı elde edilmiştir. Bu çalışma, ViT modelinin düşük sayıda görüntüye sahip modellerde birçok dezavantaja sahip olduğunu göstermektedir.

*Şahin ve arkadaşları (2024)*, çalışmalarında beyin tümörü görüntülerini ViT modelini kullanarak sınıflandırmışlardır. Ancak, bu modelin çok sayıda kritik hiperparametresi olması nedeniyle, istenen sınıflandırma performansına ulaşamamıştır. Bu sorunları kısmen ele almak için ViT modelinin Bayes Çok Amaçlı optimizasyon yöntemi ile etkileşimli kullanımı geliştirilmiştir. Performans açısından, optimize edilmiş ViT modeli, doğrulama doğruluğunda %1.48'lik bir artış, F1 puanında %3.23'lük bir yükseliş ve hassasiyette %3.36'lık bir iyileştirme ile önemli performans artışları elde etmiştir. *Amin ve arkadaşları (2025)*, DieT transformer modelini kullanarak resimlerden özellik çıkarma, PCA ile boyut azaltma ve ADE algoritmasıyla özellik seçimi içeren son teknoloji bir metodoloji geliştirerek beyin tümörlerinin çok sınıflı sınıflandırılmasını araştırmışlardır. ADE\_DieT olarak önerilen model %96.09 doğruluk oranına ulaşmıştır.

ViT yöntemi birçok çalışmada kullanılmıştır. Örneğin, Facebook AI Research tarafından geliştirilen Swin Transformer (Liu vd., 2021) modeli, ViT'in görsel görevler için alternatif bir yaklaşım olarak kullanılabilirliğini göstermiştir. Benzer şekilde, Microsoft Research'ün ResT (Zhang ve Yang, 2021) modeli, ViT yönteminin daha verimli ve daha hızlı çalışması için çeşitli iyileştirmeler sunmaktadır. ViT modelini kullanan bir diğer çalışma, video tabanlı verileri sınıflandırabilen ViViT (Arnab vd., 2021) modelidir. ViT'in başarısı, görüntü sınıflandırması gibi birçok görüntü işleme görevi için daha genel ve ölçeklenebilir yaklaşımında yatmaktadır. Bu nedenle, ViT'in gelecekte daha geniş bir görüntü işleme görevi yelpazesinde kullanılması beklenmektedir.

## 1.5. Tezin Yapısı

Birinci bölümde, tez çalışması boyunca çözülmesi gereken problemin tanımı, tezin amacı, tezin önemi, çalışmanın zorlukları ve sınırlılıkları ile derin öğrenme yöntemleri kullanılarak beyin tümörünün tespit ve sınıflandırılmasına yönelik yapılan çalışmaların literatür özeti hakkında bilgi verilmektedir. Tezin sonraki bölümleri aşağıdaki gibi düzenlenmiştir.

İkinci bölümde, çalışmanın kavramsal çerçevesi kapsamında beyin tümörlerinin gruplandırılması, bu tez çalışmasına konu olan beyin tümörü türleri, tümör tanı ve tespitine yönelik kullanılan medikal görüntüleme teknikleri anlatılmaktadır.

Üçüncü bölümde, yapay zekâ, derin öğrenme gibi kavramlara değinilerek derin öğrenme algoritmalarının çalışma prensipleri anlatılmıştır. Ayrıca, sınıflandırma probleminin çözümünde kullanılan ESA'lar, VGG-16 Evrişimli Ağ, Görüntü Transformatörü derin öğrenme modeli ve bu modellerin önemi yine bu bölümde açıklanmaktadır.

Dördüncü bölümde, veri toplama süreci ve veri setleri, veri analizinde kullanılan yöntem ve teknikler ile ön işleme adımları ve araştırmanın metodolojisi anlatılmaktadır. Bununla birlikte, veri setindeki MR görüntülerinin nasıl kullanıldığı ve beyin tümörü tespiti için bir sınıflandırıcı derin öğrenme modelinin nasıl eğitildiği, hangi parametrelerin kullanıldığıyla ilgili uygulama detayları hakkında bilgi verilmektedir.

Beşinci bölümde, veri setleriyle yapılan deneysel çalışmaların sonucunda beyin tümörünün derin öğrenme algoritmalarıyla tespiti ve sınıflandırılmasına yönelik olarak elde edilen bulgulara yer verilmektedir. Ayrıca, eğitim süresince kullanılan parametreler detaylandırılmış ve eğitimi tamamlanan modelleri değerlendirmek için kullanılan performans metrikleri açıklanmıştır.


Son bölümde ise, tez çalışması sürecinde elde edilen sonuçlar tartışılmış, yorumlanmış ve araştırmacılar için geleceğe yönelik yapılabilecek çalışmalar hakkında önerilere yer verilmiştir.



## 2. BEYİN TÜMÖRÜ

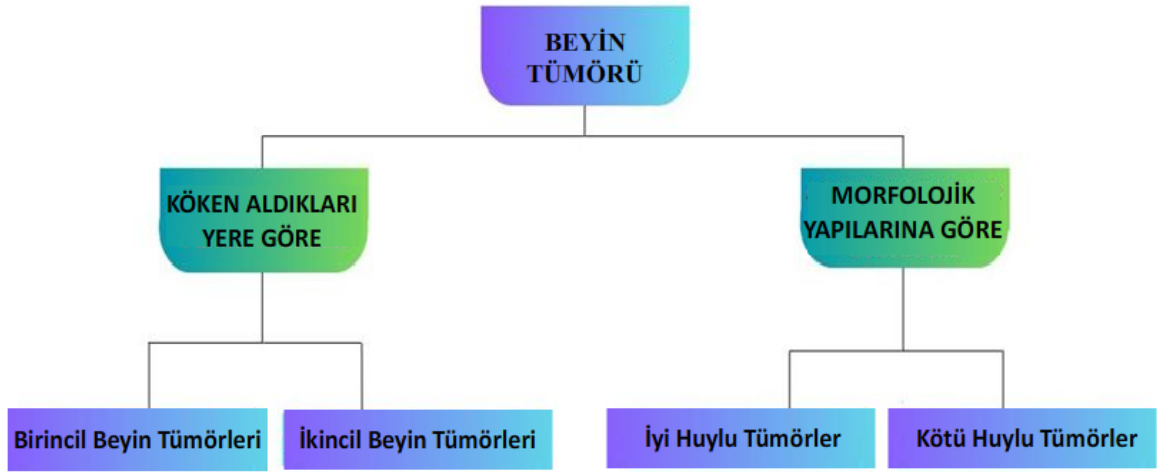
Tümör kelimesi hücrelerin anormal büyümesi sonucu meydana gelen “neoplazma” kelimesinin eş anlamlısıdır. “Neoplazma” ise canlının kontrolü dışında sınırsız çoğalabilen, hareket edebilen normal olmayan bir doku anlamına gelir. Genellikle sürekli ve hızlı büyüyen tümörlerin vücut dokusunu tahrip etmesiyle kanser hastalığı oluşur. Kanserli hücrelerin bir araya gelmesiyle tümör denilen kitle oluşur. Bu kitle sadece bir organı etkileyebileceği gibi başka organlara sıçraması (metastaz) ile yayılımı arttırabilir (Bali, 2020).

Beyin tümörü temel olarak, beynin içinde kontrolsüz bir şekilde büyümeye başlayan canlı ve ölü hücrelerin kütle benzeri bir yapısıdır (Mudda, Manjunath ve Krishnamurthy, 2020; Kaur ve Gill 2017). Genellikle beyindeki dokularda ani ve olağan dışı bir genişleme olduğunda ortaya çıkar. Bu anormal hücrelerin sayısı sabit kalmaz, çok hızlı çoğalır ve yayılmaya başlar (Mayoclinic, 2024). Şekil 1, beyin hücrelerinde oluşan örnek bir tümörün varlığını göstermektedir.



Şekil 1. Beyin dokusunda oluşan tümör (Birincil beyin tümörü) (Mayoclinic, 2024).

Bir beyin tümörü morfolojik yapılarına göre kötü huylu (malign) veya iyi huylu (benign) olabilir (Davis, 2023). İyi huylu tümörler, yavaş büyüme oranları ve düzenli sınırlara sahip olmaları ile normal görünüşleri bakımından daha az agresiftir ve iyi sınırlara sahip oldukları için cerrahi müdahale ile çıkartılabilir. Kötü huylu tümörler ise kanser hücreleri içerir ve hızla beyindeki diğer dokulara yayılmaları, çok düzensiz şekle sahip olmaları ve yaşamı tehdit edebilecek düzeyde agresif olmaları sebebiyle hastanın durumunu kötüleştirebilir. Bunun yanında beyin tümörleri, köken aldıkları yere göre birincil ve ikincil olarak ikiye ayrılır. Beynin içinde ortaya çıkan tümörler birincil, vücudun başka bir bölgesinde ortaya çıkıp daha sonra beyne doğru ilerleyen tümör tipleri ise ikincil tümörler olarak kabul edilmektedir (Swapnil ve Girish, 2020). Medikal tedavi süreci esas olarak tümör tiplerine ve yerleşimine bağlıdır. Beyin tümörlerini morfolojik yapıları, yerleşim yerleri, büyüme hızları ve son zamanlarda özellikle genetik yapılarına göre çeşitli gruplara ayırabiliriz (Dere, 2017). Şekil 2, bu gruplandırmayı sunmaktadır.



Şekil 2. Beyin tümörünün gruplandırılması

Beyin tümörleri çok küçükten çok büyüğe kadar değişebilir. Bazı beyin tümörleri çok küçükken tespit edilir, çünkü hemen fark edilen belirtilere yol açarlar. Diğer beyin tümörleri ise fark edilmeden önce oldukça büyürler. Beynin bazı bölgeleri, diğerlerine göre daha az aktiftir. Eğer bir beyin tümörü, beynin daha az aktif bir bölgesinde başlarsa, hemen belirtiler göstermeyebilir. Beyin tümörünün boyutu tümör tespit edilmeden önce oldukça büyük hale gelebilir (Mayoclinic, 2024).

Dünya Sağlık Örgütü (DSÖ), 2016 yılı içerisinde beyin tümörü sınıflandırma sistemi için birçok önemli değişiklik içeren bir güncelleme yayınlamıştır. DSÖ, beyin tümörünün fiziksel ve kimyasal özelliklerini dikkate alarak malign tümörleri dört ayrı sınıfta tanımlamıştır (Tandel vd., 2019). Aşağıda yer alan Şekil 3'te bu derecelendirme kriterleri açıklanmaktadır.



Şekil 3. Beyin tümörünün derecelendirme kriterleri

Şekil 3'te görüldüğü gibi, beyin tümörlerinin DSÖ sınıflandırması ilk defa sadece histolojiye dayalı değildir. Bir yenilik olarak beyin tümörünün sınıflandırmasına "katmanlı teşhis" anlayışı getirilmiştir. Güncellenen 2016 DSÖ, Merkezi Sinir Sistemi tümör sınıflandırma sisteminde, bazı tümör türleri morfolojik, mikroskopik, moleküler ve genetik faktörlerin bir kombinasyonu

tanımlanırken, diğerlerinin sadece morfoloji ile tanımlanmasına devam edilmektedir. Tümörün tanımlanmasında, hem MSS tümörleri için hem de daha genel olarak tümör sınıflandırması için moleküler ve genetik faktörlerin artan kullanımına yönelik mevcut eğilimin devam etmesi muhtemel görünmektedir (Johnson vd., 2017).

## 2.1. Beyin Tümörünün Oluşma Nedenleri ve En Sık Görülen Belirtileri

Beyin tümörlerinin oluşma sebepleri tam olarak bilinmemekle birlikte beyin tümörlerinden bazılarının kalıtsal geçişli olduğu kabul edilmektedir. Bunun yanında bazı risk faktörleri de söz konusudur. Bu risk faktörleri aşağıda kısaca açıklanmaktadır (Neurosurgery, 2023):

*Cinsiyet:* Beyin tümörlerinin erkeklerde daha fazla görüldüğü fakat menengiömler'a kadınlarda daha sık rastlandığı tespit edilmiştir.

*İrk:* Beyin tümörlerinin tüm türlerine beyaz ırklarda daha fazla rastlanmaktadır.

*Yaş:* Beyin tümörünün görülme sıklığı yaş bazında değerlendirildiğinde, 70 yaş üzerindeki bireylerde tümörün görülme oranı daha yüksek olup çocukluk döneminde ise 10 yaş altındakilerde beyincikte beyin tümörlerine daha sık rastlanmaktadır.

*Aile Öyküsü:* Ailesinde beyin glioması görülen bireylerde beyin tümörünün oluşma ihtimali daha fazladır. Bunların dışında; bazı virüsler, radyasyona maruz kalma, bazı kimyasal azo boyalar, kafa travması ve çeşitli hormonlar beyin tümörünün oluşumunda diğer risk faktörleri olarak sayılabilir.

Beyin tümörünün belirtileri tümörün boyutuna ve konumuna bağlı olarak değişebilir. Beyin tümörlerinin ortaya çıkardığı genel belirtiler aşağıdaki gibi sıralanabilir:

- ♦ Başta basınç hissi ve gittikçe kötüleşen baş ağrıları
- ♦ Kol ve bacaklarda hissizlik, karıncalanma veya güç kaybı
- ♦ Yürüme ve denge bozuklukları
- ♦ Çift görme, bulanık görme, bulantı, kusma
- ♦ Bayılma (sara nöbetleri)
- ♦ Baş dönmesi
- ♦ Kişilik bozuklukları, unutkanlık, konuşma bozuklukları
- ♦ Basit komutları takip etmekte zorluk çekmek
- ♦ Günlük konularda karmaşa ve yorgun hissetmek.

İyi huylu beyin tümörleri ilk süreçte fark edilemeyen belirtilere neden olabilirler. Semptomlar aylar ya da yıllar içinde kötüleşebilir. Kötü huylu beyin tümörleri ise hızla kötüleşen semptomlara neden olma eğilimindedir. Aniden ortaya çıkan semptomlara sebep olurlar ve birkaç gün ya da hafta içinde kötüleşirler.

## 2.2. Beyin Tümörü Türleri


ABD merkezli Ulusal Beyin Tümörü Derneği (National Brain Tumor Society) 120'den fazla beyin tümörü türü olduğunu belirtmiştir. Çalışmamıza konu olan tümör türleri ise literatürde en sık ismi geçen; Glioma, Meningioma, Pituitary beyin tümörleridir. Bu tümör türleri aşağıda sırasıyla açıklanmaktadır.

### 2.2.1. Glioma

Gliomlar iyi huylu olabilir, ancak çoğu kötü huyludur. Glioma beyin ve omurilikte oluşan bir tümör tipidir. Beynin destekleyici dokusu olarak bilinen glial hücreler üzerinde oluşur. Birden fazla gliom tipi mevcuttur. En yaygın olanı astrositom olmakla birlikte, glioblastom, oligodendrogliom ve ependimom tipleri de bulunmaktadır. Glioblastom, en yaygın kötü huylu beyin tümörü türüdür (Mayoclinic, 2024). Gliomlar tüm beyin tümörlerinin yaklaşık olarak %30'unu oluşturmakta ve çoğunlukla kötü huylu seyretmektedir (Acıbadem, 2019). Glioma tümör tipleri aşağıda sırasıyla açıklanmaktadır.

#### 2.2.1.1. Astrositom


Beyinde ve omurilikte ortaya çıkan bir gliom tümör tipidir. Astrositler, beyindeki ve omurilikteki sinir hücrelerini destekler ve birbirine bağlar. Tümör adı verilen büyüme bu astrosit hücrelerde başlar. Astrositom her yaşta olabilir. En sık 30 ila 55 yaş arasındaki yetişkinlerde görülür. Beyindeki astrositomların belirtileri arasında; bilinç kaybı, baş ağrıları, kişilik değişiklikleri konuşma sorunları, mide bulantısı ve kusma sayılabilir. Çoğu astrositom hızlı büyür ve beyin tümörü olarak kabul edilir. Şekil 4'te astrositom beyin tümörü tipi yer almaktadır.



Şekil 4. Astrositom tümör tipi

#### 2.2.1.2. Glioblastom

Glioblastoma, yetişkinlerde en sık görülen ve agresif birincil beyin tümörüdür. Hızlı büyür ve sağlıklı dokuyu istila edip yok edebilir. DSÖ bu beyin tümörü tipine, sınıflandırmada en yüksek derece olan derece IV'ü atamıştır. Glioblastomanın standart tedavisi cerrahi, radyoterapi ve alkilleyici kemoterapiyi içerir (Wirsching ve Weller, 2017). Beyinde veya omurilikte oluşabilir. Glioblastomanın riskini artıracak faktörler; radyasyona maruz kalmak, yaşlanmak ve kalıtsal sendromlar olarak sıralanabilir. Şekil 5, glioblastom tümör tipinin görselini sunmaktadır.



Şekil 5. Glioblastoma tümör tipi

### 2.2.1.3. Oligodendroglioma

Oligodendroglioma, en sık 25 ila 45 yaş arasındaki yetişkinlerde görülen, vücut dokusunda daha hızlı hasar oluşturan ve metastatik özelliğe sahip (diffüz infiltrate) glioma türüdür (Bell vd., 2020). Oligodendroglioma, oligodendroglia öncü hücrelerinden kaynaklanan nadir bir birincil MSS tümörü olup, yaygınlığı oldukça düşük tümör tipidir. Tüm birincil MSS tümörlerinin yalnızca %2 ile %5'ini oluşturur. Bu nadir görülme, her bir milyon kişide tahmini olarak yalnızca 1-2 vakanın yıllık insidansına karşılık gelir (Berger vd., 2022; Suwala vd., 2022; Tom vd., 2022).

Tümör, oligodendrosit adı verilen hücrelerde başlar. Bu hücreler, beyin ve omurilikte elektrik sinyallerinin akışına yardımcı olan bir madde üretir ve sinir hücrelerini korur. Belirtiler arasında; baş ağrıları, denge sorunları, vücudun bir tarafında güçsüzlük, hafıza sorunları, davranış değişiklikleri ve konuşma sorunları bulunur.


### 2.2.1.4. Ependimom

Çocuklarda ikinci en sık görülen primer omurilik tümörüdür (Merhemic vd., 2016). Beyni ve omuriliği çevreleyip koruyan beyin omurilik sıvısını taşıyan geçitlerde yer alan ependimal hücrelerde oluşup yavaş büyüyen bir tümör tipidir. DSÖ 2016 yılında ependiomun güncel sınıflandırmasını önemli ölçüde değiştirmiştir (Louis vd., 2016). Bu histolojik sınıflandırma 2021 yılında DSÖ tarafından tekrar revize edilerek tümörler konumlarına ve genetik geçmişlerine göre sınıflandırılmıştır.

### 2.2.2. Meningioma

Kafatasından beyne kadar üç farklı katman bulunur: dura mater, araknoid ve pia mater. Toplu olarak bu katmanlar meninks (beyin zarı) olarak adlandırılır. Meninkste enfeksiyon olursa buna menenjit, tümör olursa menenjiom adı verilir. Menenjiyomlar çoğunlukla meninks kısmında ve özellikle meninksin bir bölümü olan araknoid zarından kaynaklı oluşmaktadır. Ancak beynin diğer parçalarında da oluşmaları mümkündür.

Menengioma, en sık görülen beyin tümörü türlerinden biridir. Yavaş büyüyen, cerrahi müdahale ile temizlenebilen tümörlerdir. Genellikle iyi huyludur ve beyin dokusuna yapışık olmazlar. Bu da ameliyat ile tamamen temizlenebilmelerini mümkün kılar. 2 cm'den küçük, 5 cm'e kadar veya nadir de olsa 7-8 cm'e kadar büyük meningiomlara rastlanabilir (Aras, 2022). Menenjiyomların çoğu birinci derece tümörler olsa da, %20'ye kadar ikinci derece veya üçüncü derecedir (Louis vd., 2007; Willis vd., 2005). Şekil 6, menenjiyom tümörünün görsel örneğini sunmaktadır.

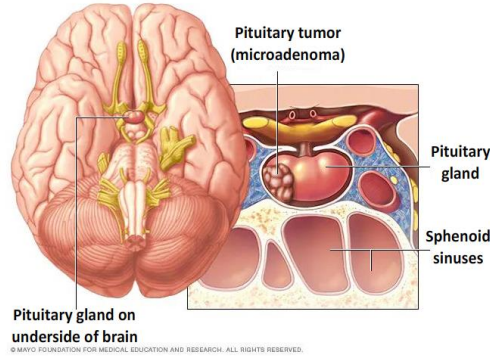


Şekil 6. Meningioma tümör tipi

Kadınlarda erkeklere oranla iki kat daha fazla görülen bir tümör türüdür. Çocuklarda ise nadir görülür. Geçirilen kafa travmaları, radyasyona maruz kalma ve genetik miras menenjiyomların oluşumuna sebep olan faktörlerden bazılarıdır. Şiddetli ve uzun süreli geçmeyen baş ağrıları en sık görülen belirtisidir. Bu belirtiler tümörün konumu ve büyüklüğüne göre şiddetlenebilmektedir. Menenjiomların genel belirtileri; baş ağrısı, bulantı ve kusma, bozulmuş mental durumlar, baş dönmesi, güçsüzlük, görme kaybı, yürümede dengesizlik, konuşmada yavaşlama ve nöbet olarak sıralanabilir.

### 2.2.3. Pituitary

Vücuttaki salgı bezlerinin kontrolünden sorumlu olan ve beyinde yer alan hipofiz bezi, üremeyi, kalp atış hızını ve büyümeyi denetler. Diğer hormon üreten bezlere komutlar veren bir orkestra şefi gibidir. Bu hormonlar da organlara sinyaller göndererek vücudun belli bir düzende çalışmasını mümkün kılar (Acıbadem, 2024). Hipofiz tümörleri, beynin alt kısmında (kafa tabanında) bulunan hipofiz bezlerinde görülen iyi huylu tümörlerdir. Yaşam boyu belirti ve zarar vermeden kalabilen hipofiz tümörü, tümörün büyümesiyle ve vücudun ihtiyaç duymadığı hormonları üretmesiyle ciddi boyutta sağlık problemleri oluşturabilir. Genellikle 25-45 yaş aralığındaki erkek ve kadınlarda görülmektedir. Medikal ve cerrahi yöntemlerle tedavi edilebilmektedir. Sıklıkla görme bozuklukları, hormonal bozukluklar ve baş ağrısı ile belirti gösterebilmektedir. Şekil 7, hipofiz tümörünün görsel örneğini sunmaktadır.



Şekil 7. Pituitary tümör tipi

En sık görülen hipofiz bezi tümörü süt salgılatan *prolaktin* hormonunun hücrelerinde oluşan tümörlerdir. Bunu, büyüme hormonunun aşırı salgılanmasıyla ortaya çıkan *akromegali*, ACTH hormonunun fazla üretildiği durumda meydana gelen Cushing hastalığı, hormon salgılamayan tümörler ile fazlasıyla hormon salgısı üreten tümörler takip etmektedir. Ayrıca tiroid uyarıcı hormon adenomu da tiroid bezi yetmezliğine ya da fazlalığına yol açan bir diğer hipofiz bezi tümör çeşididir.

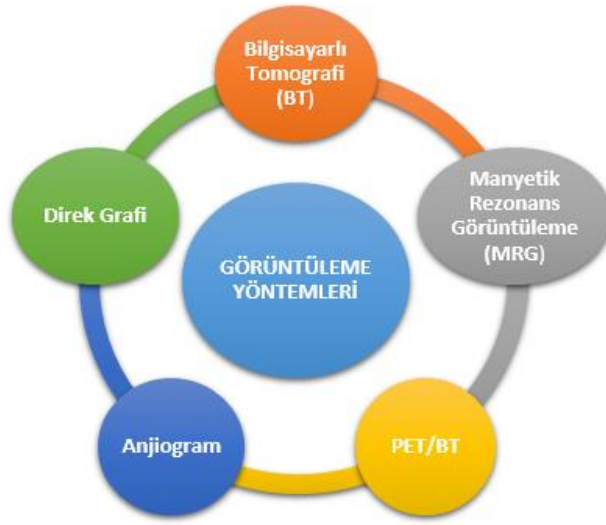
### 2.3. Beyin Tümörleri İçin Kullanılan Görüntüleme Teknikleri

Hekim, hastalık ön tanısı için hasta ve yakınlarından ayrıntılı öykü alarak tanı aşamalarına başlar. Alanında uzman hekimler (nörolog ya da beyin ve sinir cerrahı) tarafından yapılan ayrıntılı nörolojik muayene ile birçok olgu tespit edilebilmektedir. Bununla birlikte görüntüleme testleri, doktorların tümörün birincil beyin tümörü olup olmadığını veya vücudun başka bir yerinden beyne yayılmış bir tümör olup olmadığını öğrenmesine yardımcı olmaktadır. Görüntüleme testleri vücudun

içinin resimlerini gösterir. Hekim bir teşhis testi seçerken şu faktörleri göz önünde bulundurabilir (Amerikan Klinik Onkoloji Derneği-ASCO, 2021):

- ♦ Olası tümör türü
- ♦ Görülen semptomlar
- ♦ Yaş ve genel sağlık durumu
- ♦ Önceden yapılmış tıbbi testlerin sonuçları

Beyin tümörlerinin çoğu, semptomlar belirdikten sonra teşhis edilmektedir. Genellikle, bir beyin tümörü ilk olarak bir dahiliyeciy ya da nörolog tarafından fark edilir. Doktor, hastanın detaylı tıbbi geçmişini aldıktan ve fiziksel muayene yaptıktan sonra, aşağıda belirtilen testleri önerebilir. Bu testler, beyin tümörünün varlığını, bazen türünü veya evresini belirlemeye yardımcı olur. Şekil 8, beyin tümörü görüntüleme yöntemlerini sunmaktadır.



Şekil 8. Beyin tümörü görüntüleme yöntemleri (Dere (2017)'den uyarlanmıştır)

### 2.3.1. Bilgisayarlı Tomografi

Bilgisayarlı Tomografi (BT), tümörün tespiti ve ilerlemesinin izlenmesi için kullanılan geleneksel yöntemlerden biridir. Tümörün boyutunun ve şeklinin belirlenmesine yardımcı olur. 10-30 dakika süren bir BT taraması, tümör hücrelerinin besin kaynağı olarak kullandığı kan damarlarını tanımlamak için net görüntüler elde edilmesini sağlar. BT taraması, vücudun farklı açılarından x-ışınları ile iç organların fotoğraflarını çeker. Bu görüntüler, bir bilgisayar aracılığıyla birleştirilir ve tümörü ya da anormalliği gösteren ayrıntılı, üç boyutlu bir resim oluşturulur.

BT taramaları, vücudun kemikler, organlar ve yumuşak dokular gibi enine kesit görüntülerini bilgisayar yardımıyla oluşturur. X-ışınları kullanılarak gerçekleştirilen bu yöntem, oldukça ayrıntılı görüntüler sağlar. Elde edilen tarama sonuçları, tümör hücrelerine besin sağlayan kan damarlarını belirlemek için net ve keskin görseller sunar. BT rehberliğinde yapılan biyopsi işlemi, belirli bir doku örneğini almak amacıyla iğneleri doğrudan tümörün konumuna yönlendirmek için BT görüntülerinden faydalanır. Ayrıca BT taramaları, Radyofrekans Ablasyon (RFA) adı verilen, ısıyla tümörü yok etmeyi amaçlayan bir işlemle birlikte, potansiyel kanser tedavisi sağlayan ilaçların tümöre enjekte edilmesinde de kullanılabilir (Amerikan Kanser Derneği, 2015).

### 2.3.2. Manyetik Rezonans Görüntüleme

Manyetik Rezonans Görüntüleme (MRG), BT taramalarından daha ayrıntılı resimler oluşturur ve bir beyin tümörünü teşhis etmenin tercih edilen yoludur. MR taramaları ile doktorlar tümörün konumunu, boyutunu ve şeklini görsel olarak ortaya çıkarır (Rabby vd., 2024). MRG, şüphelenilen tümörün tipine ve MSS'de yayılma olasılığına bağlı olarak beyin, omurilik veya her ikisine ait olabilir. Genel olarak, bir beyin tümörünün teşhisi MRG ile başlar. MRG, beyinde bir tümör tespit ettiğinde, beyin tümörünün türünü belirlemenin en yaygın yolu biyopsi ya da ameliyat sonrası alınan doku örneğinin incelenmesidir. MRG, vücutta ayrıntılı görüntüler elde etmek için x-ışınları yerine manyetik alanlar kullanır. Bu tür modern teknolojilerin yardımıyla, erken teşhis ile başarılı tedavilerin şansı artırılmakta ve tümörle ilişkili komplikasyonların riskinin azaltılması hedeflenmektedir. Aşağıda kategorisel başlıklar halinde MRG hakkında güncel bilgiler yer almaktadır.

#### A. Çalışma Prensipleri

- MRG, güçlü bir manyetik alan oluşturarak vücuttaki hidrojen atomlarının çekirdeklerini hizalar.
- Daha sonra radyo dalgaları gönderilerek bu atomlar uyarılır ve sinyal üretmeleri sağlanır.
- Toplanan sinyaller bir bilgisayar tarafından işlenerek detaylı anatomik görüntüler elde edilir.

#### B. Beyin Tümöründe MRG'nin Avantajları

- İyonlaştırıcı radyasyon içermez, X-ray ve BT gibi iyonlaştırıcı radyasyon kullanmaz (BT'den daha güvenlidir).
- Yüksek doku kontrastı sağlar, tümör ve ödem gibi anormallikleri belirgin hale getirir.
- Farklı MRG teknikleriyle tümörün biyolojik özellikleri analiz edilebilir.
- Tedaviye yanıtı değerlendirmek ve hastalığın seyrini takip etmek için idealdir.

#### C. MRG'nin Dezavantajları

- *Manyetik Alan Kısıtlamaları:* Kalp pili, metal implantlar veya bazı protezleri olan hastalar için risk taşıyabilir.
- *Gürültülü ve Uzun Süreli Çekim:* Çekimler 15 dakika ile 1 saat arasında sürebilir ve yüksek sesli olabilir.
- *Kapalı Alan Korkusu (Kloastrofobi):* Bazı hastalar için rahatsız edici olabilir.

#### D. Beyin Tümörlerinde Kullanılan MRG Teknikleri

- *T1 Ağırlıklı MRG:* Beyin yapısını detaylı gösterir. Kontrast madde (gadolinium) verildiğinde tümörler daha belirgin hale gelir.
- *T2 Ağırlıklı MRG:* Tümör içindeki sıvı birikimini ve ödemi gösterir. Tümör çevresindeki anormal dokuların belirlenmesine yardımcı olur.
- *Difüzyon Ağırlıklı MRG (DWI):* Tümörlerin hücresel yoğunluğunu belirler. Yüksek hücre yoğunluğuna sahip agresif tümörlerde sinyal değişiklikleri oluşturur. İnme ve *malign gliomaların* ayırt edilmesine yardımcı olur.

- ♦ *Perfüzyon MRG (PWI):* Beyin tümörünün damar yapısını ve kanlanmasını gösterir. *Malign (kötü huylu) tümörler genellikle daha fazla kanlanmaya sahiptir*, bu yüzden bu teknik kanserin derecesini belirlemede kullanılır.
- ♦ *Fonksiyonel MRG (fMRI):* Beyindeki kan akış değişikliklerini inceleyerek beyin aktivitesini haritalandırır. Beyindeki *motor, konuşma ve duyuşsal bölgelerin* tümöre yakınlığını gösterir. Özellikle ameliyat planlamasında cerrahların tümörün çıkarılmasına karar vermesine yardımcı olur.
- ♦ *Manyetik Rezonans Spektroskopi (MRS):* Tümörün biyokimyasal yapısını analiz eder. Malign tümörlerde hücrel metabolizmanın değiştiğini göstererek tümörün agresif olup olmadığını anlamaya yardımcı olur.
- ♦ *Manyetik Rezonans Anjiyografi (MRA):* Damar yapılarını görüntülemek için kullanılır. Tümörün damarlarla ilişkisini belirler. Ameliyat öncesi tümörün damar yapısını anlamak için kullanılır.

### **E. Kontrastlı MRG ve Beyin Tümörü**

- ♦ Bazen tümör dokusunun daha net görünmesini sağlamak için *gadolinium bazlı* kontrast maddeler kullanılır.
- ♦ Kan beyin bariyerinin bozulduğu yerlerde kontrast tutulumunu artırır.
- ♦ Malign tümörler genellikle kontrast maddeyi daha fazla tutar.
- ♦ Genellikle güvenlidir, ancak böbrek rahatsızlığı olan hastalarda dikkat edilmelidir.

MRG, medikal görüntülemeye en gelişmiş ve en detaylı yöntemlerden biri olup, özellikle beyin tümörleri gibi hastalıkların tanı ve takibinde büyük rol oynamaktadır. Farklı MRG teknikleri sayesinde tümörlerin detaylı incelenmesi mümkün olabilmektedir. MRG'ler cerrahi ve medikal tedavi planlamasında kritik bir öneme sahiptir. Yüksek doku kontrastı ve iyonlaştırıcı radyasyon içermemesi nedeniyle BT gibi diğer görüntüleme tekniklerine göre daha güvenli ve detaylı sonuçlar sunar.

### **2.3.3. Direk Grafi**

Kökenini kafatasından alan veya kafatasında şekil bozukluğu oluşturan tümörlerde ilk aşamada tercih edilen bir yöntemdir.

### **2.3.4. Anjiogram**

BT ve MRG gibi gelişmiş tanı yöntemlerinin kullanılmadığı dönemlerde sıkça başvurulan bir tanı tekniğiydi. Günümüzde ise genellikle ileri tetkik ve tedavi amaçlarıyla kullanılmaktadır.

### **2.3.5. PET/BT**

Birçok merkezde mevcut olmamakla birlikte, genellikle metastatik beyin tümörlerinin teşhis edilmesinde kullanılmaktadır (Dere, 2017).

### 3. YAPAY ZEKÂ

“Makineler nasıl daha zeki olabilir?” sorusundan yola çıkarak geliştirilen Yapay Zekâ (YZ), makinelerin insanın bilişsel ve öğrenme yetilerini taklit etmesi ve insana özgü akıl yürütme yeteneğini yerine getirmesi olarak tanımlanabilir. Bu terimi ilk kez kullanan ve “Yapay Zekânın Babası” olarak bilinen John McCarthy'ye göre YZ, akıllı bilgisayar programları başta olmak üzere akıllı makineler oluşturma bilimi ve mühendisliğidir.

YZ'yi standart bilgisayar programlarından ayıran en önemli unsur, çıktıların sabit fonksiyonlara veya kurallara göre değil, eğitim aşamasında öğrendiği, esnek ve eğitimde kullanılan örnek setine veya yöntemine göre değişebilen algoritmalarla oluşmasıdır. Bir diğer deyişle, insanın karşılaştığı bir soruna her zaman birebir aynı tepkiyi vermemesi, vereceği bu tepkiyi o ana kadar edindiği tecrübe ve bilgi birikiminin etkilemesi gibi YZ'nin bir duruma verdiği tepki daha önceki tepkilerine benzeyebilmekle birlikte, kendi kendine öğrenme yeteneğinin de şekillendirdiği doğrultuda özgün olacaktır (Akyel ve Akdemir Özışık, 2020).

YZ teknolojisinin tıp alanında uygulanabilirliği, 1969 yılında bulanık küme algoritmasının bu alanda kullanılabileceğinin önerilmesiyle ortaya çıkmıştır (Serhatlıoğlu ve Hardalaç, 2009). Bunun yanında, ilk defa 1985 tarihli bir çalışmada YZ'nin beyin tümörü tespitinde kullanıldığı görülmüştür (Sprincl vd., 1985). Ayrıca YZ'nin nöroşirurji alanındaki ilk uygulamaları da beyin tümörünün sınıflandırılması alanında gerçekleşmiştir (Akyel ve Akdemir Özışık, 2020). Beyin tümörünün görülme sıklığı ve YZ'nin çeşitli alt dallarının tümörün tespiti ve sınıflandırılmasında kullanılması YZ'yi sağlık bilişimi alanında önemli bir noktaya taşımaktadır. Bu temel alt dallar Şekil 9'da gösterilmekte ve alt başlıklarda sırasıyla açıklanmaktadır.



Şekil 9. Yapay zekâ unsurları

#### 3.1. Makine Öğrenmesi

Makine öğrenimi (MÖ), ampirik verileri kullanılabilir modellere dönüştürmek için hesaplama algoritmalarını kullanan bir çalışma alanıdır (Edgar ve Manz, 2017). Bu teknoloji, sistemlerin verilerden desenleri ve ilişkileri tanıyıp, bu bilgiyi yeni veriler üzerinde tahmin veya kararlar almak için kullanmalarına olanak tanır. Üç ana MÖ türü: denetimli, denetimsiz ve pekiştirmeli öğrenmedir. Denetimli öğrenmede, makine öğrenimi algoritmaları, bir veya daha fazla bağımsız değişken ile bir bağımlı değişken arasındaki ilişkileri modellemek için kullanılabilir. Denetimsiz öğrenmede,

algoritmalar veri kümelerinde anlamlı modeller bulur veya verileri gruplara ayırır. Pekiştirmeli MÖ algoritmaları, bir dizi kısıtlama veya bir ödül sistemi verildiğinde optimize edilmiş planlar veya eylem planları üretir (Algren vd., 2021).

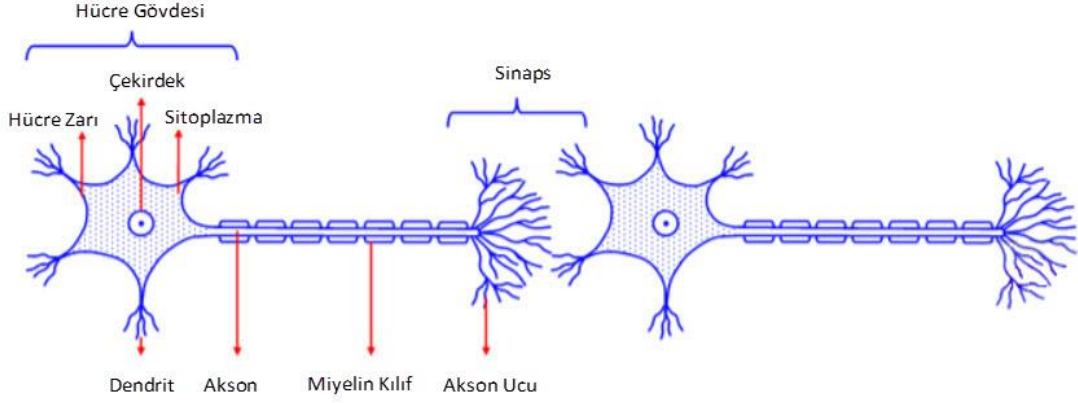
Makine öğreniminin uygulama alanları oldukça genişler ve her geçen gün daha fazla sektörde kullanılmaktadır. Sağlık, finans, perakende, otomotiv ve eğlence gibi sektörlerde, MÖ sayesinde daha hızlı ve doğru kararlar alınabilmektedir. Örneğin, sağlık sektöründe MÖ algoritmalarıyla hastalıkların erken teşhisi ve kişiselleştirilmiş tedavi yöntemleri geliştirilmektedir. Beyin tümörlerinin teşhisinde MÖ, görüntü işleme ve analizi alanında önemli bir rol oynamakta, görüntüleri otomatik olarak inceleyerek, tümörlerin varlığını, türünü ve büyüklüğünü tespit edebilen modeller geliştirilmesine olanak tanımaktadır. Ayrıca MÖ, tümörlerin evrelerini ve prognozunu tahmin etme gibi ileri düzey analizlerle de doktorlara daha iyi tedavi stratejileri geliştirme fırsatı sunmaktadır.

Makine öğreniminin, büyük veri ve güçlü hesaplama gücü ile birleşmesi, bu alanın gelecekteki potansiyelini daha da artırmaktadır. Bu sayede, daha verimli ve akıllı sistemler tasarlanmakta, insanların yaşam kalitesi artırılmaktadır. MÖ'nün birçok biçimi olmasına rağmen (Örneğin; Rastgele Ormanlar, Destek Vektör Makineleri, k-En Yakın Komşu vd.), derin öğrenme baskın yaklaşım olarak ortaya çıkmıştır. DÖ, yapay sinir ağları adı verilen karmaşık matematiksel yapılar oluşturmayı ve eğitmeyi içerir. Yapay sinir ağları, beyin dokusunda gözlemlenen biyolojik öğrenme süreçlerinden, özellikle de Hebbian öğrenmesinden esinlenmiştir (Ellis ve Teo, 2024).

### 3.2. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beyninin mimarisini taklit etmeye çalışan hesaplamalı modellerden oluşan bir YZ yaklaşımıdır. Bununla birlikte, makine öğreniminde yaygın olarak kullanılan yöntemlerden biridir (Geçmez ve Gençler, 2021). YSA'larda veriler ayrı "elemanlar" veya "nöronlar" halinde işlenir ve bu elemanlar arasında sinir sinapslarını simüle eden "bağlantılar" yoluyla aktarılır. Yapay nöronlar genellikle şu katmanlarda düzenlenir: giriş, gizli ve çıktı katmanı. Giriş katmanındaki nöronlar araştırmacılar tarafından sağlanan verileri hesaplar; tek veya çoklu gizli katmanlardaki elemanlar verilerin çoklu varyasyonlarının geliştirilmesine izin verir; çıktı katmanı ise model tarafından tahmin edilen "cevabı" hesaplar. Verilere çeşitli matematiksel işlevler uygulanır ve geri yayılım, olasılıksal ve benzerleri gibi çeşitli YSA modelleri ortaya çıkar (Marchevsky, 2007).

1949'da Donald Hebb, yapay nöronlar ve davranışları hakkında birkaç temel kavram tanımlamıştır. 1959'da Stanford'dan Bernard Widrow ve Marcian Hoff ADALINE ve MADALINE (Çoklu Uyarlanabilir Doğrusal Elemanlar) YSA modellerini geliştirdiler. MADALINE, telefon hatlarındaki yankıları ortadan kaldıran uyarlanabilir bir filtre sağlamakta ve gerçek dünya problemine uygulanan ilk YSA olma özelliğini taşımaktadır. Bugün hala ticari olarak kullanılmaktadır. YSA'lar, bir öğrenme algoritması ve girdi verileri yardımıyla nöronlar arasındaki bağlantıların ağırlıklarını ve yanlılıklarını düzenleyerek bu görevleri yerine getirecek şekilde eğitilebilir. Şekil 10'da bir sinir hücresinin modeli ve temel bileşenleri yer almaktadır.

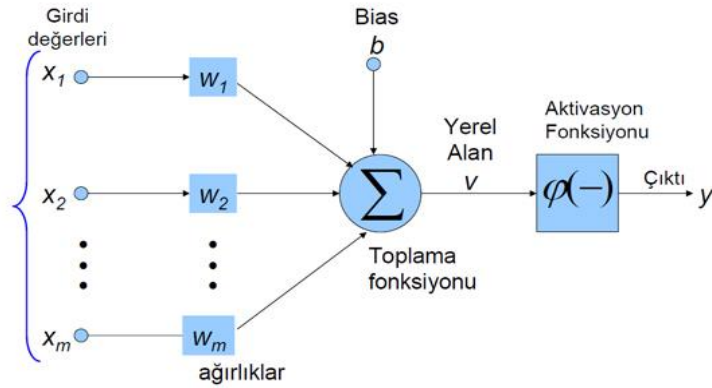


Şekil 10. Sinir hücresi modeli ve sinir hücresi bileşenleri

Sinir hücresinde; diğer hücrelerden gelen sinyalleri hücrenin çekirdeğine aktaran yapı “dendrit”, bu sinyalleri toplayan bölüm “soma” ve bu bilgiyi diğer hücre bileşenlerine ileten kısmı “akson” olarak tanımlanır. Aksonların taşıdığı veriyi diğer hücrelerin dendritlerine aktaran ve bu veri üzerinde ön işlem gerçekleştiren yapıya ise “sinaps” denir. Sinapslar aracılığıyla iletilen sinyaller, belirli eşik fonksiyonlarının ortaya koyduğu denklem değerlerine göre aktarılır. Sinapsların, öğrenme sürecinin gerçekleştiği temel yapı olduğu öne sürülmektedir.

Bir nöron, sinir ağının çalışmasında temel rol oynayan bir bilgi işleme birimidir. Şekil 11’de yer alan blok diyagram, çeşitli sinir ağı türlerinin tasarımına temel teşkil eden bir nöron modelini göstermektedir. Bu modelde, nöronun üç ana bileşeni tanımlanmaktadır.

- 1- Her biri kendine özgü ağırlığı veya etkisiyle tanımlanan bir dizi sinaps veya bağlantı halkası (*Ağırlıklar*).
- 2- Giriş sinyallerini, ilgili sinaptik ağırlıklarla çarparak toplayan bir birleştirici (*Toplama Fonksiyonu*); bu işlem doğrusal bir kombinasyon oluşturur.
- 3- Nöronun çıktısının genliğini belirli bir aralıkta tutmak için kullanılan bir *Aktivasyon Fonksiyonu*.



Şekil 11. Yapay sinir hücresi

Şekil 11 incelendiğinde, bir sinir ağı, n adet nöron girişi ve bir bias değerini giriş olarak alır ve bu girdilerin ağırlıklı toplamını çıkışa iletir. Bias'ın eklenmesiyle birlikte, aktivasyon fonksiyonuna girecek olan *Net Girdi* elde edilir. Çıkış değeri, aktivasyon fonksiyonundan geçirilerek son şekline ulaşır. Sinir ağlarının modeli, girişlerin ağırlıklarıyla çarpılıp toplanması ve bu toplamın aktivasyon fonksiyonuna uygulanması prensibine dayanır. Aktivasyon fonksiyonu, sinir hücresinin etkinleştirilip etkinleştirilmeyeceğini belirler. Son olarak, bu çıktılar farklı yapılarla birleştirilerek yapay sinir ağları oluşturulur.

Net Girdi (NG) Denklem 1'de verilen matematiksel model ile hesaplanmaktadır.

$$NG = \sum_{i=1}^n X_i W_i + b + y \quad (1)$$

Aktivasyon fonksiyonları, doğrusal (linear) ve doğrusal olmayan (non-linear) olmak üzere iki ana gruba ayrılır. Çoğunlukla, bu fonksiyonlar doğrusal olmayan yapıda olur. Aktivasyon fonksiyonunun temel amacı, sinir ağına doğrusal olmayan özellikler kazandırarak daha karmaşık örüntüleri öğrenmesine yardımcı olmaktır. Bu nedenle, doğrusal aktivasyon fonksiyonları karmaşık problemleri çözmede yeterince etkili olmadıkları için pek tercih edilmez.

Bu fonksiyonlar, her bir nöronun çıktısını belirli bir aralığa, genellikle 0 ile 1 veya -1 ile 1 arasına normalleştirir.

YSA'lar, bir girdi verisi üzerinde tahminler yapan ve öğrenen YZ sistemleridir. Bu tahmin süreci, sinir ağının farklı katmanlarında yer alan çeşitli bileşenler aracılığıyla gerçekleşir (Önal, 2023). Bu bağlamda, *Threshold (Basamak) fonksiyonu*, katmanlardaki bileşenlerin çıktılarını hesaplamada kullanılan bir matematiksel modeldir. Genellikle, bir girdi verisinin çıktısını 0 veya 1 olarak düzenleyen bir sınırlama mekanizmasına sahiptir. Threshold fonksiyonu, doğrusal aktivasyon fonksiyonları kategorisine girer ve mühendislik alanında *Heaviside fonksiyonu* olarak da bilinir. Bu fonksiyonun matematiksel ifadesi aşağıda yer alan Denklem 2'de gösterilmektedir.

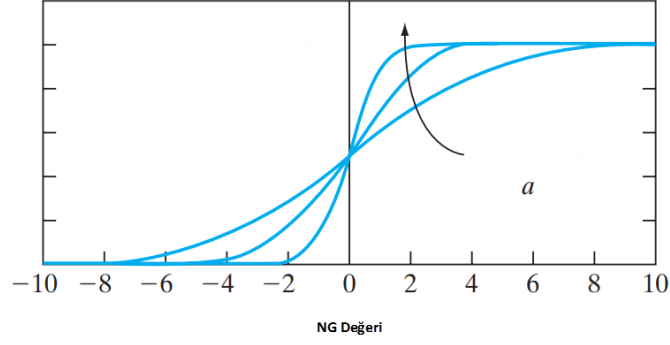
$$f(NG) = \begin{cases} 0, & NG < 0 \\ 1, & NG \geq 0 \end{cases} \quad (2)$$

Bu fonksiyonun işleyişinde, NG değeri sıfırdan küçükse fonksiyonun çıktısı 0 olur. NG değeri sıfıra eşit ya da sıfırdan büyük olduğunda ise fonksiyonun çıktısı 1 olur.

Yaygın olarak kullanılan doğrusal olmayan (non-linear) aktivasyon fonksiyonları arasında *Sigmoid*, *Tanh*, *ReLU (Rectified Linear Unit)*, *Leaky ReLU* ve *Softmax* yer alır. Sigmoid aktivasyon fonksiyonu, herhangi bir gerçek sayıyı 0 ile 1 arasındaki bir değere dönüştürür. Denklem 3'te Sigmoid aktivasyon fonksiyonunun matematiksel gösterimi yer almaktadır.

$$f(NG) = \frac{1}{1+e^{-NG}} \quad (3)$$

*Sigmoid fonksiyonu*, ağırlık değişikliklerinin yavaş yapılmasını sağlar, bu da ağın eğitim sırasında daha yumuşak bir öğrenme eğrisi oluşturmasına yardımcı olur.




Şekil 12. Sigmoid fonksiyonu değer grafiği

Şekil 12’de gösterilen *Sigmoid fonksiyonu* grafiğinde  $a$  parametresi değiştirilerek farklı eğimlerde sigmoid fonksiyonları elde edilir. Orijindeki eğim aslında  $a/4$ ’e eşittir. Eğim parametresi sonsuza yaklaştıkça, sigmoid fonksiyonu basitçe bir threshold fonksiyonu haline gelir. Threshold fonksiyonu yalnızca 0 veya 1 değerini alırken, sigmoid fonksiyonu 0 ile 1 arasında sürekli bir değer aralığına sahiptir. Ayrıca, sigmoid fonksiyonunun türevlenebilir olduğunu, oysa threshold fonksiyonunun türevlenemediğini unutmamak önemlidir.

*Softmax aktivasyon fonksiyonu*, yapı itibarıyla *Sigmoid fonksiyonuna* oldukça benzerdir. NG değerine karşılık olarak 0 ile 1 arasında bir değer döndürür. Genellikle sınıflandırma problemlerinde kullanılan softmax, iki sınıftan fazla olan (çoklu sınıf) durumlarda sigmoid fonksiyonuna alternatif olarak tercih edilir. Bu fonksiyon, bir tahminin belirli bir sınıfa ait olma olasılığını 0 ile 1 arasında bir değerle ifade ederek olasılıksal bir yaklaşım sunar. *Softmax aktivasyon fonksiyonunun* matematiksel ifadesi Denklem 4’te verilmiştir.

$$f(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (4)$$

Denklem 4’te,  $z_i$  ve  $z_j$  girdi verisinin  $i$ . ve  $j$ . özelliklerini,  $f(\vec{z})_i$  ise  $i$ . sınıfı için çıktı değerini temsil eder. Bu fonksiyon,  $e^{z_i}$  değerini tüm sınıflar için  $e^{z_j}$  değerlerinin toplamına böler ve böylelikle olasılık değerlerini elde eder. Ayrıca, *Softmax fonksiyonu*, modelin belirsiz olduğu durumlarda, yani girdi verisinin farklı sınıflara ait olasılıklarının birbirine yakın olduğu hallerde, üretilen çıktı değerlerinde yüksek bir değişkenlik sağlar. Bu sayede, modelin güvensiz olduğu durumlar daha net bir şekilde gözlemlenebilir.

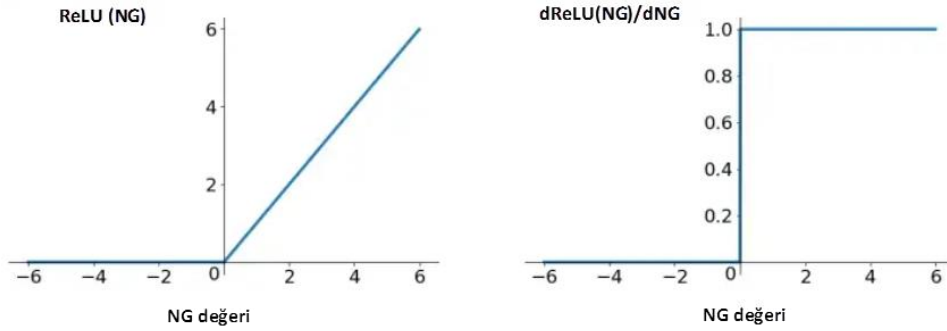


Şekil 13. Softmax aktivasyon fonksiyonu değer grafiği

*ReLU (Rectified Linear Unit) aktivasyon fonksiyonu*, birçok YSA için oldukça popüler bir aktivasyon fonksiyonudur. Bu fonksiyon, negatif girdi değerleri için 0, pozitif girdi değerleri içinse doğrudan girdi değerinin kendisini döndürür. ReLU fonksiyonunun birimleri basit bir şekilde uygulanabilir ve pek çok farklı uygulamada etkili olduğu kanıtlanmıştır. *ReLU fonksiyonu* maksimum değer alır. *ReLU aktivasyon fonksiyonunun* matematiksel gösterimine Denklem 5'te yer verilmiştir.


$$f(NG) = \begin{cases} 0, & NG < 0 \\ NG, & NG \geq 0 \end{cases} \quad (5)$$

*ReLU fonksiyonunun* en büyük faydalarından biri, sinir ağına non-lineerlik eklemesidir, bu da daha karmaşık desenleri öğrenmesini kolaylaştırır. Bunun yanında, *ReLU fonksiyonu* yalnızca basit aritmetik işlemler kullandığı için hesaplama açısından oldukça verimlidir. Ancak, ReLU fonksiyonunun bazı sınırlamaları bulunmaktadır. Bunlardan biri, “ölü ReLU” adı verilen bir sorundur; bu durumda bazı nöronlar eğitim sırasında aktif olamayabilir ve sürekli olarak 0 çıktısı verir. Bu, nöronların eğitim sürecine katılmaması nedeniyle ağın öğrenme kapasitesini düşürebilir. Bu sorunu çözmeye yönelik varyantlar, negatif giriş değerleri için küçük bir negatif eğim sağlayan “leaky ReLU” gibi fonksiyonlar sunmaktadır.



**Şekil 14.** ReLU ve dReLU aktivasyon fonksiyonu değer grafikleri

YSA'lar; *Giriş Katmanı*, *Ara (Gizli) Katmanlar* ve *Çıkış Katmanı* olmak üzere üç ana katmanda incelenir. Bilgiler, ağın giriş katmanına iletilir ve buradan ara katmanlarda işlenip çıktı katmanına gönderilir. YSA'lar katman yapılarına göre tek ve çok katmanlı olmak üzere ikiye ayrılır. Eğer ağ, birden fazla nöron ve gizli katmandan oluşuyorsa buna *Çok Katmanlı Sinir Ağı (Multilayer Artificial Neural Network)* denir. Sadece tek bir katmandan oluşuyorsa, buna *Tek Katmanlı Sinir Ağı (Single Layer Artificial Neural Network)* adı verilir. Şekil 15'te YSA'ların katman yapısı gösterilmektedir.



Şekil 15. Yapay sinir ağları katmanları

### 3.3. Derin Öğrenme

Derin öğrenme (DÖ), YSA'ları kullanan, üç veya daha fazla katmandan oluşan bir makine öğrenimi yaklaşımıdır (Aslan vd., 2023). DÖ modelleri, bağımsız olarak öğrenebildikleri ve karmaşık görüntü özelliklerine odaklanabildikleri için geleneksel MÖ algoritmalarına göre daha fazla tercih edilmektedir. DÖ yaklaşımlarında özellik çıkarımını iyileştirmek için sürekli olarak yeni modeller geliştirilmekte ve bu yaklaşımlar farklı tıbbi alanlarda kullanılmaktadır. DÖ teknikleri, görüntü işleme, sınıflandırma ve segmentasyon dahil olmak üzere uygulamalar için yaygın olarak kullanılan bir dizi yöntemi kapsar (Houssein vd., 2022). DÖ oluşturmak için Evrişimli Sinir Ağı, Derin İnanç Ağı (DİA) ve Tekrarlayan Sinir Ağı (TSA) olmak üzere üç yaygın mimari kullanılmaktadır. DİA, genel sınıflandırma problemlerinde yaygın olarak kullanılırken, TSA, veriler daha sıralı formda olduğunda kullanılır. Bununla birlikte, görüntü, metin ve ses sınıflandırması söz konusu olduğunda ESA daha popülerdir (Ganatra ve Patel, 2018).

DÖ, özellikle büyük veri kümeleri üzerinde çok güçlü sonuçlar verir. Görüntü tanıma, ses işleme, doğal dil işleme gibi alanlarda yaygın olarak kullanılır. Örneğin; bir sinir ağı bir fotoğraftaki nesnelere tanıyabilir, bir metindeki duyguyu analiz edebilir veya bir konuşmayı metne çevirebilir. Derin öğrenmenin çalışma mantığı aşağıda adım adım anlatılmaktadır:

**A. Veri Girişi (Input):** DÖ modeli, metin, görüntü, ses veya sayısal veriler gibi ham veriler alır. Bu veriler, sayısal tensörler (matrisler) şeklinde modele beslenir.

**B. Katmanlar (Layers):** Derin öğrenme modelleri, çok sayıda gizli katman (hidden layers) içerir. Temel katmanlar:

- ♦ *Girdi Katmanı (Input Layer):* Ham verinin modele ilk girdiği katmandır.
- ♦ *Gizli Katmanlar (Hidden Layers):* Modelin öğrenmeyi gerçekleştirdiği, çoğunlukla nöronlardan oluşan katmanlardır. Bunlar verinin özelliklerini çıkarır, ilişkileri öğrenir ve dönüşümler uygular.
- ♦ *Çıktı Katmanı (Output Layer):* Modelin tahmin veya sınıflandırma yaptığı son katmandır.

- C. Ağırlıklar ve Biaslar:** Her bağlantının bir ağırlığı (weight) ve bir bias değeri vardır. Model, veriden öğrenirken bu ağırlıkları ve biasları optimize ederek doğru sonuçlara ulaşmaya çalışır.
- D. Aktivasyon Fonksiyonları:** Gizli katmanlardaki her nöron, gelen veriyi bir aktivasyon fonksiyonundan geçirir. Aktivasyon fonksiyonu, modele doğrusal olmayan ilişkiler öğrenme yeteneği kazandırır. Yaygın aktivasyon fonksiyonları:
- ♦ *ReLU (Rectified Linear Unit):* Maksimum(0, x) fonksiyonudur, negatif değerleri sıfırlar.
  - ♦ *Sigmoid:* Verileri 0-1 aralığına çeker, genellikle olasılık tahminlerinde kullanılır.
  - ♦ *Softmax:* Sınıflandırma problemlerinde, olasılık dağılımı sağlar.
- E. İleri Yayılım (Forward Propagation):** Girdi verisi modele verilir, her katmandaki nöronlar veriyi işler ve bir sonraki katmana iletir. Bu işlem, çıktı katmanına kadar devam eder. Nihayetinde bir tahmin veya çıktı üretilir.
- F. Hata Hesaplama (Loss Function):** Modelin ürettiği çıktı ile gerçek etiket arasındaki fark, bir kayıp fonksiyonu (loss function) aracılığıyla hesaplanır. Örneğin:
- ♦ *Mean Squared Error (MSE):* Regresyon problemlerinde kullanımı yaygındır.
  - ♦ *Cross-Entropy Loss:* Sınıflandırma problemlerinde kullanılır.
- G. Geri Yayılım (Backpropagation):** Hatanın modelin hangi parametrelerinden kaynaklandığını belirlemek için türev ve zincir kuralı kullanılarak hata geriye doğru yayılır. Bu sayede ağırlıklar ve biaslar güncellenir.
- H. Optimizasyon (Optimization):** Modelin parametreleri (ağırlık ve biaslar), optimizasyon algoritmalarıyla güncellenir. En çok kullanılan algoritmalar:
- ♦ *Stochastic Gradient Descent (SGD):* Basit ama etkili bir yöntemdir.
  - ♦ *Adam Optimizer:* Değişken öğrenme hızlarıyla çalışan gelişmiş bir optimizasyon algoritmasıdır.
- İ. Eğitim (Training):** Model, veriler üzerinde birçok döngü (epoch) boyunca ileri yayılım, hata hesaplama, geri yayılım ve optimizasyon işlemlerini tekrarlar. Amaç, hatayı minimize ederek en doğru tahminleri yapabilen bir model oluşturmaktır.
- J. Test ve Değerlendirme:** Eğitim tamamlandıktan sonra model, daha önce görmediği test verisiyle değerlendirilir. Modelin performansı, doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) gibi metriklerle ölçülür.

DÖ, beyin tümörü teşhisi ve sınıflandırılmasında da dikkate değer bir etki yaratmıştır. Özellikle tıbbi görüntüleme (MRG, BT taramaları gibi) ve büyük veri analizindeki gücü sayesinde, doktorlara hızlı, doğru ve objektif teşhisler konusunda ciddi bir yardımcı haline gelmiştir. Bu sürecin nasıl işlediği ve derin öğrenmenin bu alandaki etkileri aşağıda adım adım açıklanmaktadır:

1. **Görüntü İşleme ve Özellik Çıkarma:** Beyin tümörü teşhisi için en çok kullanılan veriler MRG taramalarıdır. Bu görüntülerden tümörün varlığını ve tipini tespit etmek için belirli özelliklerin çıkarılması gerekir. Geleneksel yöntemler bu özellikleri manuel olarak belirlerken, DÖ modelleri görüntülerin ham piksel verisinden anlamlı özellikleri kendisi öğrenir.
  - ♦ *Evrişimli Sinir Ağları*, bu alanda en sık kullanılan DÖ mimarisidir. ESA'lar, görüntüdeki kenarlar, dokular, şekiller gibi görsel kalıpları katmanlar aracılığıyla öğrenir.
  - ♦ MRG taramalarındaki gri tonlar, kontrast farkları ve anormallikler ESA'ların dikkatle işlediği özelliklerdir.
2. **Tümör Tespiti ve Segmentasyon:** Bir MRG görüntüsünde tümörün varlığı ve konumu belirlenmelidir. Bu aşamada “görüntü segmentasyonu” devreye girer. DÖ tabanlı segmentasyon algoritmaları, görüntüdeki her pikselin hangi dokuya ait olduğunu belirler (Örneğin sağlıklı doku, ödem, tümör).
  - ♦ *U-Net* gibi modeller, tıbbi görüntü segmentasyonunda çok etkilidir. U-Net, hem düşük seviyeli detayları hem de yüksek seviyeli yapıları aynı anda analiz ederek tümörün şeklini ve büyüklüğünü çok hassas bir şekilde çıkarır.
  - ♦ *Mask R-CNN* gibi yöntemler, hem tümörün yerini belirler hem de şekilsel özelliklerini tanımlar.
3. **Tümör Sınıflandırma:** Beyin tümörleri, farklı türlerde ve farklı malignite seviyelerinde olabilir. DÖ, tümörlerin tiplerini otomatik olarak sınıflandırmada çok güçlüdür:
  - ♦ *Glioma, Meningioma, Pituitary Adenoma* gibi yaygın beyin tümörü türlerini sınıflandırmak için ESA tabanlı modeller başarıyla kullanılır.
  - ♦ *Transfer Öğrenme* yöntemleri, önceden eğitilmiş modeller (ResNet, VGG, EfficientNet gibi) kullanarak beyin tümörü sınıflandırmasında daha hızlı ve etkili sonuçlar sağlar.
  - ♦ *Tekrarlayan Sinir Ağları* veya *Transformer* modelleri, zaman serisi verisi içeren 3D MRG veya çoklu dilimli taramaları analiz etmek için kullanılabilir.
4. **Doğruluk ve Güvenilirlik:** DÖ modelleri, genellikle geleneksel yöntemlerden daha yüksek doğruluk oranlarına ulaşır. Özellikle büyük ve dengeli veri kümeleri üzerinde eğitildiğinde yüksek performans sergiler.
  - ♦ %90'ın üzerinde doğruluk oranı sağlayan ESA modelleri yaygındır.
  - ♦ Yanlış negatif ve yanlış pozitif oranları ciddi şekilde azalır, bu da erken teşhis ve doğru tedavi planlamasında kritik bir rol oynar.

## 5. Derin Öğrenmenin Avantajları:

- ♦ *Hız:* Bir MR görüntüsünün analizini saniyeler içinde tamamlar.

- ♦ *Objektiflik*: İnsan yorumu veya yorgunluğu gibi faktörlerden etkilenmez.
- ♦ *Otomasyon*: Özellik çıkarımı, tespit, segmentasyon ve sınıflandırma gibi adımları uçtan uca otomatize edebilir.
- ♦ *Genelleştirilebilirlik*: Farklı merkezlerden gelen MR görüntülerine adapte edilebilir.

**6. Zorluklar ve Gelecek Yönelimleri:** Her ne kadar DÖ'nün potansiyeli büyük olsa da bazı zorluklar da söz konusudur. Bunlar:

- ♦ *Veri Yetersizliği*: Etiketlenmiş tıbbi veri az ve pahalıdır.
- ♦ *Veri Çeşitliliği*: Farklı cihazlardan gelen MR görüntülerinin kalite farkları modele yansiyabilir.
- ♦ *Model Şeffaflığı*: DÖ modelleri genellikle "kara kutu" gibidir; kararların nasıl verildiğini anlamak zor olabilir.

Bu zorlukları aşmak için *Açıklanabilir Yapay Zekâ (XAI)* yöntemleri, *Veri Artırma (Data Augmentation)* ve *Federe Öğrenme (Federated Learning)* gibi yaklaşımların kullanımı önerilmekle birlikte popüler hale gelmektedir.

DÖ, beyin tümörü teşhisi ve sınıflandırmasında hassasiyet, hız ve doğruluk açısından muazzam bir katkı sağlamaktadır. Özellikle karmaşık tıbbi görüntülerin analizinde insan gözünün kaçırabileceği detayları yakalayabilmekte ve erken teşhis imkanını da artırmaktadır.

### 3.3.1. Derin Öğrenme Kütüphaneleri

DÖ kütüphaneleri, derin öğrenme algoritmalarını pratik ve erişilebilir bir şekilde kullanmak amacıyla tasarlanmış yazılım araçlarıdır. Bu kütüphaneler, DÖ modellerinin oluşturulması, eğitilmesi ve test edilmesi için gerekli olan çeşitli fonksiyonları barındırır. Başlıca önemli DÖ kütüphaneleri şunlardır:

*TensorFlow*: Google tarafından geliştirilen, açık kaynaklı bir DÖ kütüphanesi olan TensorFlow, MÖ algoritmalarının hesaplama süreçlerini ve durumlarını tanımlamak için veri akışı grafikleri kullanır. Bu grafiklerde, her düğüm belirli bir matematiksel işlemi (örneğin, matris çarpımı) temsil ederken, her kenar veri bağımlılığını ifade eder. Kenarlar arasında taşınan bilgiler, tensör adı verilen n boyutlu dizilerle tanımlanır ve bu tensörler veri formatını belirler (Jia vd., 2021).

*Keras*: Python diliyle yazılmış yüksek seviyeli bir DÖ kütüphanesi olan Keras, TensorFlow üzerinde çalışabilme özelliğiyle öne çıkar. Keras, endüstriyel düzeyde performans ve ölçeklenebilirlik sunar; NASA, YouTube ve Waymo gibi kurumlar tarafından aktif olarak kullanılmaktadır (Keras.io, 2021).

*MXNet*: Çoklu dil desteği sağlayan açık kaynaklı bir DÖ kütüphanesidir. Bu özelliği sayesinde, farklı programlama dilleri kullanılarak yapılan çalışmalarda karşılaştırma yapma olanağı sunmaktadır.

*PyTorch*: Facebook tarafından geliştirilen bir DÖ kütüphanesidir. Son yıllarda PyTorch, TensorFlow'a kıyasla sunduğu geliştirilmiş kullanılabilirlik sayesinde araştırmacılar arasında hızla popülerlik kazanmıştır (Pérez-García, Sparks & Ourselin, 2021). Torch tabanlı bu kütüphane, görüntü işleme, resim, video ve ses verilerinin işlenmesi gibi birçok alanda kullanılmaktadır. Lua ve

Python programlama dillerini destekleyen PyTorch, karmaşık problemlere yönelik algoritmaları hızlı ve esnek bir şekilde oluşturma yeteneğiyle öne çıkmaktadır (Toğaçar ve Ergen, 2019).


*Caffe*: “Hızlı Özellik Gömme için Evrişimsel Mimari” anlamına gelen Caffe kütüphanesi, özellikle önceden eğitilmiş modeller sunmasıyla öne çıkar. Açık kaynak kodlu bu derin öğrenme çerçevesi, görüntü sınıflandırma ve görüntü segmentasyonu gibi farklı görevler için çeşitli DÖ mimarilerini destekler. *LSTM*, *CNN*, *R-CNN* ve tam bağlantılı sinir ağları gibi popüler yapılarla uyumlu çalışarak esnek ve güçlü bir çözüm sunmaktadır.

Zengin kütüphanelere sahip olması DÖ'nün birçok alanda başarılı şekilde kullanımını mümkün kılmaktadır. Bu kütüphaneler sayesinde, derin öğrenme modelleri oluşturabilir, veri setini modelin eğitimi için kullanabilir ve modelin tahmin başarımını değerlendirebiliriz.

Tezin bu bölümü, tümörün teşhisi ve sınıflandırılmasına yönelik kullanılan DÖ tabanlı yöntemlerin anlatımıyla devam etmektedir.

### 3.3.2. Evrişimsel Sinir Ağları

Özellikle görüntülerin analizinde kullanılan Evrişimsel Sinir Ağları (ESA), çok katmanlı ileri beslemeli bir yapay sinir ağıdır (Doğan ve Türkoğlu, 2019). ESA'lar görüntülerin tanımlanması ve doğal dil işlemeye dayalı sınıflandırma modellerinin başarıyla oluşturulup geliştirilmesinde önemli rol oynar. ESA mimarisi; sağlık alanında hastalıkların teşhisinde, görüntü ve ses tanımda, bilgisayar görmesi, metin ve video işlemede ve diğer birçok alanda yüksek başarı göstermektedir. İnsanlardaki görme sistemini baz alan ESA ile yapay sistemlerde amaç; nesnelere algılanması, tanımlanması ve sınıflandırılmasıdır. ESA'lar, bilinen konvolüsyon (evrişim) işlemi ve YSA'ların birleşiminden oluşmaktadır. Şekil 16'da ESA mimarisinin görsel bir örneği yer almaktadır.



Şekil 16. Evrişimli sinir ağı modeli

ESA, çok sayıda katmandan oluşan hiyerarşik bir yapıdır. ESA mimarisi incelendiğinde; modelde giriş katmanı, konvolüsyon katmanları, havuzlama katmanları, tam bağlantılı katman ve çıkış katmanı bulunmaktadır. ESA mimarisinde, her bir evrişim katmanını, doğrusal olmayan bir fonksiyonu tanımlayan doğrultulmuş lineer birim (ReLU) ve sonrasında ise havuzlama katmanı takip etmektedir. Bu katmanlar aşağıda kısaca açıklanmaktadır:

#### A. Evrişim (Convolutional) Katmanı:

- ♦ ESA'nın temel yapı taşıdır.
- ♦ Görüntü gibi giriş verisi üzerinde belirli boyuttaki filtreler (kernel) kaydırılarak yerel özellikler çıkarılır.
- ♦ Bu işlem, kenar, köşe, doku gibi düşük seviyeli özellikleri tanımlamaya başlar.

- ♦ Her filtre farklı bir özelliği öğrenir ve çıktı olarak bir *özellik haritası (feature map)* üretir.

### **B. Aktivasyon (Activation) Fonksiyonu:**

- ♦ Her evrişim katmanından sonra, ağırlıklı toplamdan elde edilen değeri doğrusal olmayan bir fonksiyonla işler.
- ♦ En yaygın aktivasyon fonksiyonlarından biri *ReLU (Rectified Linear Unit)*'dur.
- ♦ ReLU, negatif değerleri sıfıra çeker ve ağırlık öğrenmesini hızlandırır.

### **C. Havuzlama (Pooling) Katmanı:**

- ♦ Özellik haritalarının boyutunu küçültür ve modele yerel değişmezlik kazandırır.
- ♦ *Maksimum havuzlama (Max pooling)* en sık kullanılan yöntemdir: belirli bir alandaki en büyük değeri alır.
- ♦ *Ortalama havuzlama (Average pooling)* ise belirli bir alandaki ortalama değeri alır.
- ♦ Bu katman, hesaplama maliyetini düşürür ve aşırı öğrenmeyi (overfitting) önlemeye yardımcı olur.

### **D. Düzleştirme (Flatten) Katmanı:**

- ♦ Çok boyutlu özellik haritalarını tek boyutlu bir vektöre dönüştürür.
- ♦ *Tam bağlı (fully connected)* katmanlara geçişi sağlar.

### **E. Tam Bağlı (Fully Connected) Katman:**

- ♦ Düzleştirilen vektörü kullanarak öğrenilen özellikleri bir sınıflandırıcıya dönüştürür.
- ♦ Girdi ve çıktındaki her nöronun birbiriyle bağlantılı olduğu klasik YSA katmanıdır.
- ♦ Son katmanda genellikle *Softmax* veya *Sigmoid* aktivasyon fonksiyonları kullanılır, böylece sınıflandırma yapılır.

### **F. Dropout Katmanı (Opsiyonel):**


- ♦ Aşırı öğrenmeyi önlemek için bazı nöronları rastgele devre dışı bırakır.
- ♦ Modelin genelleme yeteneğini artırır.

Bir ESA modeli, bu katmanların kombinasyonuyla çalışır. İlk katmanlar genellikle düşük seviyeli özellikleri (çizgiler, kenarlar) öğrenirken, ağ derinleştikçe daha karmaşık ve soyut özellikler yakalanır.

### **3.3.3. VGG-16 Evrişimli Ağ**

VGG-16, Oxford Üniversitesi'nden K. Simonyan ve A. Zisserman tarafından "Büyük Ölçekli Görüntü Tanıma için Çok Derin Evrişimli Ağlar" konulu makalelerinde önerdikleri bir ESA modelidir (Hassan, 2018). Asıl model 2014'teki ILSVRC ImageNet Challenge sırasında sunulmuştur. ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC), görüntü sınıflandırma ve nesne algılama için algoritmaları değerlendiren yıllık bir yarışmadır. Bu yarışmada bilgisayarla görme alanında kendini kanıtlayan model, röntgen veya MRG gibi tıbbi

görüntüleme yapılarak hastalık teşhisi için kullanılabilir. VGG-16 modelinin ayrıntılı katman yapılandırması Şekil 17’de sunulmuştur.



Şekil 17. VGG-16 modeli

Bu model, mimari boyunca  $3 \times 3$  filtre boyutu kullanır. Softmax’a evrişim katmanı da dahil olmak üzere 16 katmandan oluşur, bu nedenle VGG-16 olarak adlandırılır (Rai ve Chatterjee, 2020). Tüm konfigürasyonlar arasında VGG-16, ImageNet veri setinde en iyi performans gösteren model olarak belirlenmiştir (Thite, 2024). Bilgisayarla görme alanında sonraki yeniliklerin yolunu açmış ve daha küçük alıcı alanların yığılmış evrişim katmanları fikri, bu modelin çığır açan bir yeniliği olarak kabul görmüştür. Modern ESA’ların çoğu hala bu yığılmış evrişim bloğunu kullanmaktadır.

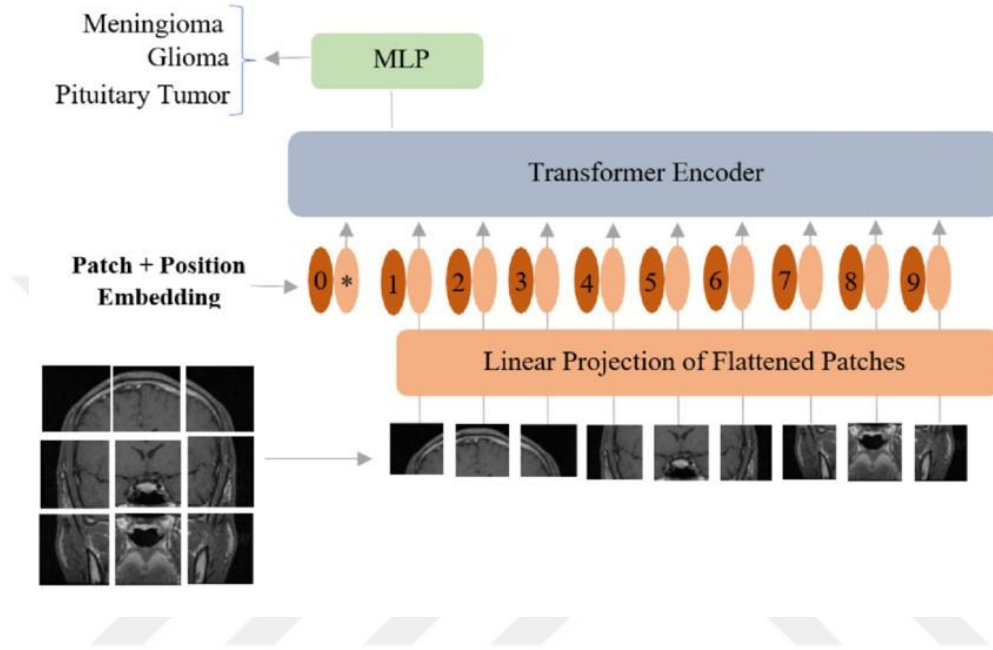
VGG-16, toplamda 13 evrişim katmanı, 5 havuzlama katmanı ve 3 tam bağlı (fully connected) katmandan oluşur. İlk birkaç evrişim katmanı düşük seviyeli özellikler (kenarlar, dokular) çıkarırken, derinleştikçe model daha karmaşık yapıları öğrenir. Her evrişim katmanının ardından bir ReLU aktivasyon fonksiyonu uygulanır, bu da modele doğrusal olmayan bir öğrenme kapasitesi kazandırır. Havuzlama katmanları, boyut küçültme ve modelin hesaplama yükünü azaltma işlevi görür. En sonunda yer alan tam bağlı katmanlar, sınıflandırma işlemini gerçekleştirir ve genellikle bir softmax aktivasyon fonksiyonu ile son bulur. VGG-16’nın bu derin yapısı, yüksek doğruluk sağlamasına rağmen, parametre sayısının fazlalığı nedeniyle yüksek hesaplama gücü ve bellek gereksinimi duyar.

### 3.3.4. Vision Transformer (ViT) Modeli

Transformatör modellerinin yeteneklerinden yararlanarak görüntülerden özellik çıkarma, günümüzde yeni bir çalışma alanıdır. Dikkat mekanizmasına dayanan Görüntü Transformatörü (ViT) derin öğrenme modeli, görüntü işlemede transformatörlerin yeteneklerinden yararlanmayı öneren alanda öncü bir çalışmadır (Dosovitskiy vd., 2020). ViT modeli; tıbbi görüntüler, havacılık, tarım gibi birçok alanda kullanılmıştır. Görüntü sınıflandırma ve görüntülerden özellik çıkarmada kullanılabilen model, ESA tabanlı modellere kıyasla üstün başarı elde edebilmektedir (Maurício vd., 2023).

ViT modeli, değişen görüntü boyutlarını anlama ve bunları küresel olarak değerlendirme konusunda ESA modellerine göre daha esneklerdir (Ibrahim vd., 2022). Modelin bir diğer önemli avantajı da görüntünün uzak bölgeleri arasındaki ilişkileri yakalama yeteneğidir. ViT modelinde görüntüler 16 ve 32 gibi önceden belirlenmiş parçalara bölünerek işlenir. ESA modellerinde, görüntü üzerinde dolaşan ve özellikleri çıkaran bir filtre, yakın konumlardaki özellikler arasındaki ilişkileri

yakalamada iyi olsa da, uzak ilişkileri belirlemede başarısız olabilmektedir. ViT modelinde görüntünün parçalara ayrılması, ESA modellerindeki bu dezavantajı ortadan kaldırır ve uzak ilişkilerin yakalanmasını kolaylaştırır. Düzensiz verilerle çalışabilme yeteneği ViT modelinin bir diğer üstün yönüdür. Bunun yanında, ViT'lerin gücünden tam olarak yararlanmak için büyük miktarda veri gerekir ve tıbbi görüntüleme alanlarında bu miktarda veri toplamak mümkün olmayabilir (Tummala vd., 2022). ViT modelinin görsel bir yapılandırması Şekil 18'de sunulmaktadır.



Şekil 18. Vision Transformer (ViT) model diyagramı

## 4. MATERYAL ve METOT

Beyin tümörünün derin öğrenme algoritmalarıyla tespiti ve sınıflandırılmasına yönelik olarak çalışmanın bu bölümünde; veri toplama süreci ve veri setleri, veri analizinde kullanılan yöntem ve teknikler ile araştırmanın metodolojisi açıklanmaktadır.

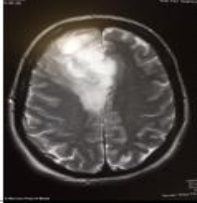
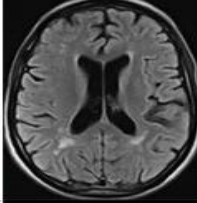
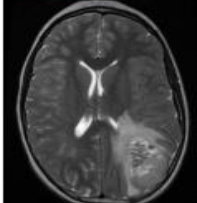
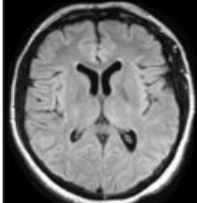
### 4.1. Veri Temin Süreci

Bu tez çalışmasının verileri için Fırat Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu'ndan etik kurul onayı alınmış ve Elazığ Fethi Sekin Şehir Hastanesi'nden resmi yazışmalarla beyin tümörüne ilişkin BT ve MR görüntüleri talep edilmiştir. Temin edilen görüntü setiyle deneyler gerçekleştirilmiş fakat görüntü sayısının az olması sebebiyle beklenen performans çıktılarına ulaşamamıştır. Bu süreçte tez çalışmasının yöntemi için farklı parametrelerle farklı derin öğrenme modelleri geliştirilmiş ve değerlendirme metriklerine göre en yüksek performans sağlayan yöntem tez yöntemi olarak seçilmiştir.

Ek veri seti temini için beyin tümörü araştırmacılarına girdi sunan web platformları incelenmiş ve Kaggle sitesinden hazır veri setleri indirilmiştir. Hastaneden temin edilen verilerle gerçekleştirilen deneysel süreçlerde geliştirilen yöntem ve modeller, bu elde edilen hazır veri setleriyle tekrar denenmiş ve yüksek performans bulgularına ulaşıldığı görülmüştür. Aşağıda bu veri setleri sırasıyla açıklanmakta ve bir sonraki bölümde deneysel çıktılar sunulmaktadır.


### 4.2. Veri Seti-1

Beyin MR görüntüleri, araştırmacı analizleri için, metriklerin ve MÖ algoritmalarının kullanımına girdi sunan Kaggle web platformundan alınmıştır. Veri seti toplamda 253 görüntü içeren iki klasörden oluşmaktadır. Birinci klasörde tümörsüz 98 görüntü varken, ikinci klasörde tümör içeren 155 görüntü mevcuttur. Veri setinden bir kesit Şekil 19'da sunulmuştur.

Sınıflandırma	Tümörlü	Tümörsüz
VERİ SETİ		
		
Toplam veri sayısı	155	98

Şekil 19. Veri seti-1'den görsel örnekler ve sayıları


Veri setindeki tüm görüntüler evet ve hayır içeren iki klasördedir. Verilerle çalışmayı kolaylaştırmak için veri seti-1; eğitim, val ve test klasörlerine bölünmüştür. Yeni klasör hiyerarşisi aşağıdaki gibi görünecektir (Şekil 20).



Şekil 20. Yeni klasör hiyerarşisindeki dokuz dizin

### 4.3. Veri Seti-2

Bu veri setini içeren görüntüler Kaggle web platformundan alınmıştır (URL-13). Veri seti toplamda 7023 görüntü içeren eğitim ve test klasörlerine bölünmüştür. 5712 veri eğitim için (81.3%), 1311 veri ise test için (18.7%) ayrılmıştır (Şekil 21). Her klasörün dört alt klasörü vardır (Glioma\_tumor, meningioma\_tumor, no\_tumor, pituitary\_tumor). Bu klasörler, ilgili tümör sınıflarının MRG'lerine sahiptir.




Şekil 21. Veri seti-2'nin bölünme oranı

Veri setindeki tüm görüntüler eğitim ve test görüntülerini içeren iki klasördedir. Verilerle çalışmak için veri seti; glioma, meningioma, pituitary ve tümör yok klasörlerine bölünmüştür. Veri setinden bir kesit Şekil 22'de sunulmuştur.

SINIFLANDIRMA		<i>Glioma_Tumor</i>	<i>Meningioma_Tumor</i>	<i>No_Tumor</i>	<i>Pituitary_Tumor</i>
VERİ SETİ -2	TEST				
	EĞİTİM				
TOPLAM		1621	1645	2000	1757
7023					

Şekil 22. Veri seti-2'den görsel örnekler ve sayıları

Şekil 22 incelendiğinde, test ve eğitime ayrılmış verilerden; 1621 görüntü glioma tümör, 1645 görüntü meningioma tümör, 2000 görüntü tümör yok ve 1757 görüntü ise pituitary tümörü içermektedir. MR görüntülerinin sınıflandırma yüzdelerine Şekil 23'te yer verilmiştir.



Şekil 23. Veri seti-2'de yer alan tümör tiplerinin yüzdelerine dağılımı


#### 4.4. Veri Seti-3

Veri kümesi-3 bilimsel çalışmalar için halka açık veri sunan Kaggle web platformundan ücretsiz indirilmiştir. Veri seti toplamda 3264 görüntü içermektedir (URL-14). 2870 veri eğitim için, 394 veri ise test için ayrılmıştır. Her klasörün dört alt klasörü vardır (Glioma\_tumor, meningioma\_tumor, no\_tumor, pituitary\_tumor). Bu klasörler, ilgili tümör sınıflarının MRG'lerine sahiptir. Veri setinden bir kesit Şekil 24'te gösterilmektedir.

SINIFLANDIRMA		<i>Glioma_Tumor</i>	<i>Meningioma_Tumor</i>	<i>No_Tumor</i>	<i>Pituitary_Tumor</i>
VERİ SETİ -3	TEST				
	EĞİTİM				
TOPLAM		926	937	500	901
		3264			

Şekil 24. Veri seti-3'ten görsel örnekler ve sayıları

Veri setindeki tüm görüntüler eğitim ve test görüntülerini içeren iki klasördedir. Verilerle çalışmak için veri seti; glioma, meningioma, pituitary ve tümör yok klasörlerine bölünmüştür. Test ve eğitime ayrılmış verilerden, 926 görüntü glioma tümör, 937 görüntü meningioma tümör, 500 görüntü tümör yok ve 901 görüntü ise pituitary tümörü içermektedir. Yeni klasör hiyerarşisi aşağıdaki gibidir (Şekil 25).



Şekil 25. Yeni klasör hiyerarşisindeki dizinler

#### 4.5. Önerilen Metodoloji

Çalışmada, görüntülerdeki özellikleri tanımlamak ve tıbbi durumları teşhis etmek için, başarılı algoritma sınıflandırması sunan ESA ve yine bir ESA modeli olan VGG-16 kullanılmıştır. VGG-16, basitliği ve etkinliğinin yanı sıra görüntü belirtileri ve nesne tanıma dahil olmak üzere çeşitli bilgisayarlı görme görevlerinde güçlü performans elde etme yeteneği ile öne çıkmaktadır. Ayrıca çalışmamızda düşük veri miktarına sahip veri kümelerinde, transformatör tabanlı derin öğrenme modellerinin sınıflandırma başarısına damıtma tekniklerinin etkisi incelenmiştir. Bu kapsamda araştırmamızda, transformatör tabanlı ancak damıtma tekniklerini kullanmayan ViTx32 ve ViTx16 modelleri ile damıtma tekniklerini kullanan DeiT ve BeiT modelleri önerilmektedir.

#### 4.6. Ön İşleme

Veri kalitesi, çalışmanın yanlış analitik sonuçlardan ve yanlış iş kararlarından arındırılması için oldukça önemlidir. Bu durumda ön işleme veri kalitesini artıran gerekli adımlardır. Özellikle beyin gibi karmaşık doku yapısına sahip görüntüler üzerinden sınıflandırma yapabilmek güç olduğu için görüntü kalitesinin belirli bir seviyede olması zorunludur. Bu sebeplerle eğitimden önce görüntülerin ön işleme tabi tutulması gerekir. Bu çalışmada kullanılan görüntüler, normalleştirme, bazı kırpma ve yeniden boyutlandırma gibi ön işlemlerden geçirilmiş, gürültüler giderilmiş ve görüntü kalitesi artırılmıştır. Bu adımlar aşağıda sırasıyla açıklanmaktadır.

Görüntü verilerini çalışma alanına yüklemek için veri seti dizini google drive üzerinden tanımlanır. Programa dahil edildikten sonra görüntüler gürültülerden arındırılmak için ön işleme tabi tutulur. Aşağıda program kodlarından bir kesit sunulmaktadır.

```


...
def plot_confusion_matrix(cm, classes,
normalize=False,
title='Confusion matrix',
cmap=plt.cm.Blues):
plt.figure(figsize=(6,6))
plt.imshow(cm, interpolation='nearest', cmap=cmap)
plt.title(title)
plt.colorbar()
tick_marks = np.arange(len(classes))
plt.xticks(tick_marks, classes, rotation=90)
plt.yticks(tick_marks, classes)
if normalize:

```

```
cm = cm.astype('float') / cm.sum(axis=1)[:, np.newaxis]
...
```

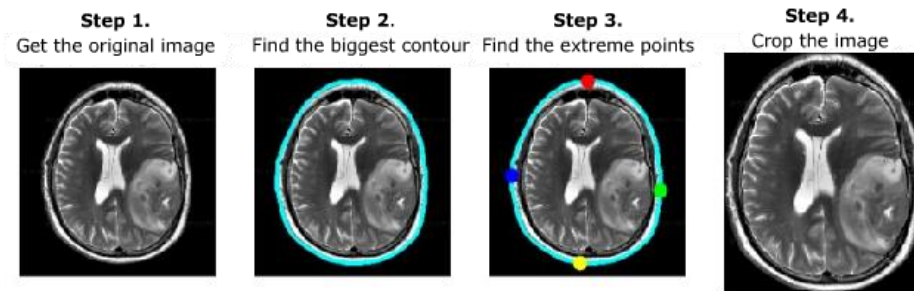
#### 4.6.1. Normalizasyon, Görüntü Kırpma ve Yeniden Boyutlandırma

Her insanın kafa büyüklüğünün farklı olması analizi zorlaştırmaktadır. Bu sorunun giderilmesi için görüntülerin aynı koordinat düzlemine oturtulması amacıyla normalizasyon işlemi gerçekleştirilmiştir (Şekil 27). Görüntüler farklı genişlik ve yüksekliğe ve farklı boyutlarda 'siyah köşelere' sahiptir. ESA VGG-16 girdi katmanı için görüntü boyutu (224, 224) olduğundan görüntüler yeniden boyutlandırılmıştır. Oran dağılımlarının histogramı Şekil 26'da verilmiştir (Oran=genişlik/yükseklik).




Şekil 26. Görüntülerin dağılım oranları

Normalleştirme adımlarında bir kontur boyunca aşırı kuzey, güney, doğu ve batı (x, y) koordinatlarının bulunması için OpenCV ve Python kullanılmıştır.




Şekil 27. Normalleştirme adımları

Veri seti-1 ile yapılan çalışmada, VGG-16 modeli ve ağırlıkları ile TÖ kullanılmıştır. Veri kümemiz küçük olduğu için, eğitim kümesinin boyutunu artırmaya yardımcı olan 'Veri büyütme' tekniği uygulanmıştır. Aşağıda büyütülmüş bir veri örneğine yer verilmiştir (Şekil 28).



Şekil 28. Artırılmış görüntüler

Veri setlerine ön işlem adımları uygulanarak gereksiz, bozuk alanlar ve gereksiz arka planlar görüntülerden çıkarılmış, modelin performansı ve görüntünün doğru sınıflandırılması için gerekli işlem adımları gerçekleştirilmiştir. Bu amaçla görüntülere kırpma işlemi uygulanmış ve yeniden boyutlandırılmıştır. Böylece modelin sadece özelliklerin bulunduğu bölgelere odaklanması sağlanmıştır. Şekil 29’da kırpılmış ve yeniden boyutlandırılmış görüntü örneklerine yer verilmiştir.



Şekil 29. Kırpılan ve 224×224 olarak yeniden boyutlandırılan görüntü örnekleri

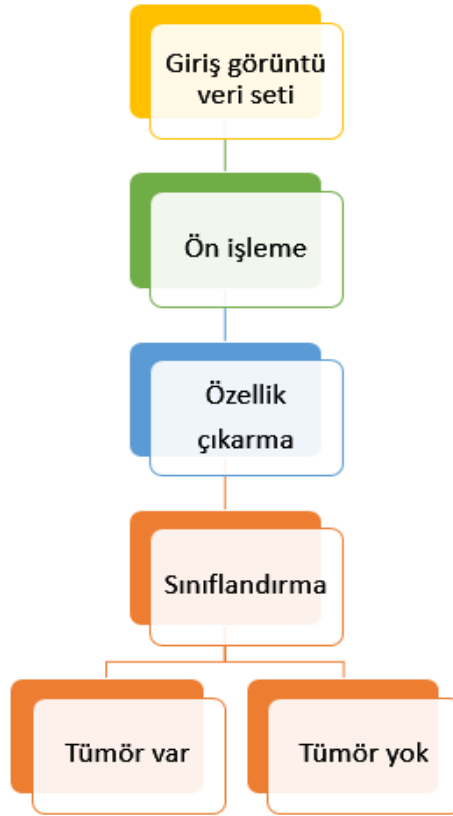
## 5. BULGULAR

Bu bölümde; veri setleriyle yapılan deneysel çalışmaların sonucunda beyin tümörünün derin öğrenme algoritmalarıyla tespiti ve sınıflandırılmasına yönelik olarak elde edilen bulgular sırasıyla sunulmaktadır.

### 5.1. ESA, VGG-16 Yaklaşımına Dayalı Derin Öğrenme Kullanılarak Beyin Tümörünün Tespit Edilmesine İlişkin Geliştirilen Model ve Deneysel Bulgular

#### 5.1.1. Veri Seti ve Uygulama Detayları

Veri seti-1 (tümörsüz 98, tümörlü 155 olmak üzere toplamda 253 görüntü) kullanılarak gerçekleştirdiğimiz çalışmamızda, DÖ için önerilen hesaplama modeli, bir ESA ve VGG-16 yaklaşımını içermektedir. DÖ stratejilerinde, ESA'lar en sık kullanılan sınıflandırıcıdır. Özellikle beyin tümörlerinin sınıflandırılmasında daha fazla dikkat çekmiştir. Şekil 30, önerilen model için tespit sürecini göstermektedir.



Şekil 30. Önerilen yöntem için teşhis süreci

Veri bilimi, YZ ve DÖ araştırmacılarına projelerini geliştirirken Python kodlarını yazma ve çalıştırma fırsatı sunan, etkileşimli ve bulut tabanlı Colab veya bir diğer adı ile “Colaboratory” platformu üzerinden bu çalışma programlanmıştır. Model oluşturulma aşamasında kullanılan parametrelerin özet bilgileri aşağıda yer alan Tablo 1’de gösterilmektedir.

**Tablo 1.** Önerilen ESA, VGG-16 modelinin özet bilgileri

<b>Katman</b>	<b>Çıktı şekli</b>	<b>Parametre</b>
VGG-16 (Functional)	(None, 7, 7, 512)	14714688
Flatten (Flatten)	(None, 25088)	0
Dropout (Dropout)	(None, 25088)	0
Dense (Dense)	(None, 1)	25089
Toplam parametreler (Total params): 14.739.777		
Eğitilebilir parametreler (Trainable params): 25.089		
Eğitilemeyen parametreler (Non-trainable params): 14.714.688		

Tablo 1, VGG-16 modelinin parametre yapısını ve katman bazındaki çıktıları detaylı şekilde göstermektedir. VGG-16'nın evrişimsel (ESA) kısmı, (None, 7, 7, 512) boyutunda bir çıktı üretmektedir ve 14.714.688 parametreye sahiptir. Bu kısmın eğitilemeyen parametre olarak tanımlanması, genellikle önceden eğitilmiş ağırlıkların transfer öğrenmede kullanıldığını göstermektedir. Evrişim katmanları, modelin özellik çıkarımı yaptığı aşamadır ve bu büyük parametre sayısı, modelin yüksek kapasitede öğrenme yapabildiğini kanıtlar.

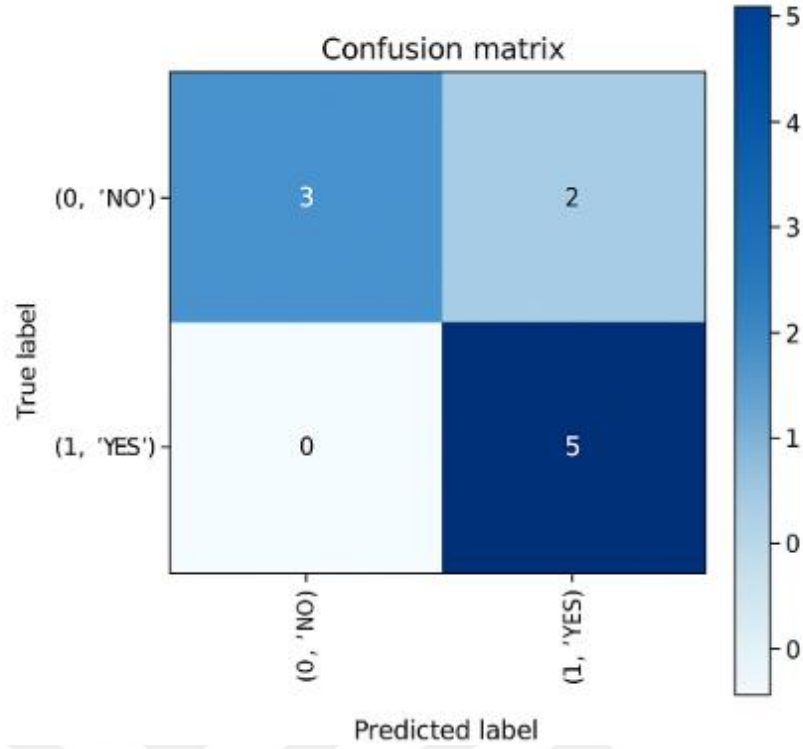
Tam bağlı (Dense) katmana geçişte, Flatten katmanı çıktıyı tek boyutlu bir vektöre dönüştürürken, Dropout katmanı da düzenleme (regularization) görevini yerine getirir. Son Dense katmanı, 25.089 eğitilebilir parametreye sahiptir ve modeli bir sınıflandırma probleminde son kararı vermek için kullanılmaktadır. Bu yapı, VGG-16'nın önceden öğrenilmiş bilgileri koruyup, yalnızca son katmanda yeni veriye göre ince ayar yaptığı transfer öğrenme yaklaşımını açıkça göstermektedir. Modelin toplam parametre sayısının 14.739.777 olması, bu derin yapının güçlü ama aynı zamanda yüksek hesaplama gerektiren bir model olduğunun da altını çizmektedir.

### **5.1.2. Deneysel Bulgular**

Bu bölümde, MR görüntülerinden beyin tümörlerinin varlığını tespit etmek amacıyla önerilen ESA-VGG-16 modelinin deneysel sonuçları ve karşılaştırmalı analizleri sunulmaktadır.

#### **5.1.2.1. Model Performansı**


Modelin performansını değerlendirmek için karışıklık matrisi kullanılmıştır. Karışıklık matrisi, sınıflandırma görevlerinde DÖ modellerinin performansını değerlendirmek için önemli bir araçtır. Doğru ve yanlış tahminlerin ayrıntılı bir dökümünü sağlayarak, modelin farklı sınıflar arasında ne kadar iyi ayırım yaptığının daha net anlaşılmasını sağlar. Örneğin, bir görüntü sınıflandırma probleminde, karışıklık matrisi modelin hangi sınıfları yanlış sınıflandırma eğiliminde olduğunu belirlemeye yardımcı olur. Bu, yalnızca genel doğruluğu ortaya çıkarmakla kalmaz, aynı zamanda modelin sürekli olarak hata yaptığı belirli alanları da vurgular. Bu nedenle, karışıklık matrisi zayıflıkları teşhis etmede ve DÖ sistemlerindeki iyileştirmeleri yönlendirmede önemli bir rol oynar. Aşağıda yer alan Şekil 31'de modelimize ait karışıklık matrisi gösterilmektedir.



Şekil 31. Karışıklık matrisi

Doğruluk oranının %80 olarak hesaplandığı karışıklık matrisini incelediğimizde modelimiz, 5 normal görüntüden 3'ünü doğru şekilde sınıflandırmıştır. Bununla birlikte, 5 tümörlü görüntüden 5'ini doğru tahmin etmiştir. Bu da modelin hassasiyetinin (Recall) 1.00 olduğunu göstermektedir. Genel olarak modelin “YES” sınıfında güçlü bir tahmin performansı sergilediği görülmektedir. Ayrıca, 0.83 olarak hesaplanan F1 skoru modelin hem hassasiyet hem de doğruluk anlamında dengeli bir performansa sahip olduğunu göstermektedir. Şekil 32, yanlış ve doğru sınıflandırılan görüntü örneklerini sunmaktadır. İki sınıfın MRG taramalarından oluşan veri seti-1'de;

- HAYIR – tümör yok, 0 olarak
- EVET – tümör var, 1 olarak kodlanmaktadır.



**Şekil 32.** Yanlış ve doğru sınıflandırılan görüntü örnekleri

Şekil 32’de verilen görüntülerin üzerinde “Actual class” (gerçek sınıf) ve “Predicted class” (tahmin edilen sınıf) bilgileri yer almaktadır. Sol tarafta yanlış sınıflandırılan örnekler (gerçek sınıf 0, tahmin edilen sınıf 1), sağ tarafta ise doğru sınıflandırılan örnekler bulunmaktadır. Sağ üst köşedeki görüntüde tümör alanı belirgin şekilde görülmekte olup, modelin doğru tahminde bulunduğu anlaşılmaktadır. Bu tür analizler, tıbbi YZ sistemlerinin güvenilirliğini artırmak ve klinik kullanıma uygun hale getirmek için önemlidir.

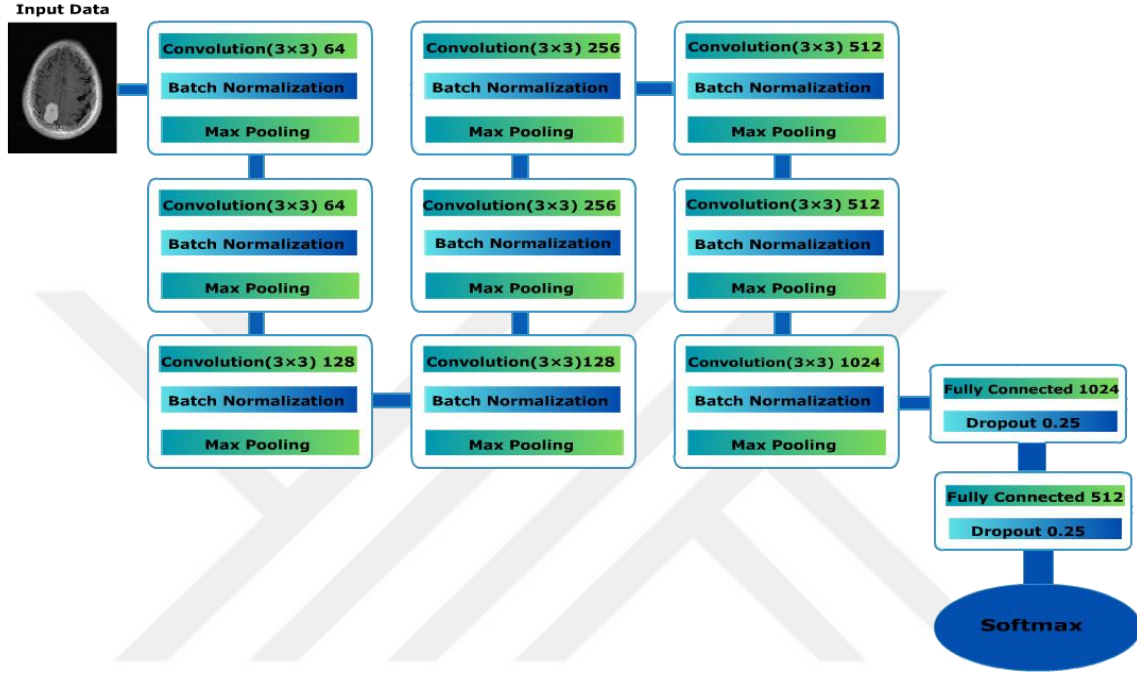
## **5.2. Verimli Yeni Bir Evrişimli Sinir Ağı Tabanlı Model Kullanarak Beyin Tümörü Görüntülerinin Çoklu Sınıflandırmasına İlişkin Geliştirilen Model ve Deneysel Bulgular**

### **5.2.1. Veri Seti ve Uygulama Detayları**

Veri seti-2 (1621 görüntü glioma tümör, 1645 görüntü meingioma tümör, 2000 görüntü tümör yok ve 1757 görüntü ise pituitary tümör olmak üzere toplamda 7023 görüntü) kullanılarak gerçekleştirdiğimiz çalışmamızda önerilen DÖ modeli bir Evrişimli Sinir Ağı içermektedir. ESA, beyin tümörlerinin tespit ve sınıflandırılmasında dikkat çeken başarılı sonuçlar ürettiğinden en sık kullanılan sınıflandırıcıdır. Çalışma, MRG kullanılarak beyin tümörünün teşhisi, tipi ve tümör konumunun tanımlanması olarak sınıflandırılmasını içermektedir.

Bu çalışmada, her bir sınıflandırma görevi için ayrı bir model kullanmak yerine farklı sınıflandırma görevlerinde beyin görüntülerini sınıflandırmak amacıyla bir model kullanılarak deneyler yapılmıştır. Sıfırdan oluşturulan yeni etkin bir ESA tabanlı çok görevli sınıflandırma sistemi, tümörün saptanması ve sınıflandırılması için geliştirilmiştir. Beyin tümörü çalışmalarının fazla sınıfsal kategori gerektirmeyen az sınıflı veri seti ile yapılması mümkün olduğundan daha basit ESA’ların geliştirilmesi yeterli olacaktır. Modelimizde aşırı öğrenme ve aşırı uydurmanın önüne geçmek için modelimizi daha fazla veri ile eğitmeye ve etkin verimli bir klasik ESA ağ mimarisi geliştirmeye odaklandık. Çalışmamızda temel ESA modelini değiştirerek, onun daha iyi bir versiyonunu geliştirdik. Beyin tümörü sınıflandırması için sıfırdan yeni bir ESA modeli tasarladık.

Mevcut ESA'nın değiştirilmesiyle tasarlanan model giriş ve çıkış katmanlarıyla birlikte 11 katmana sahiptir. Model dokuz evrişimli ve iki tam bağlantılı katmanlardan oluşmaktadır. Daha sonra ise metriklerin ve MÖ algoritmalarının kullanımına girdi sunan Kagge platformundan edinilen 7023 beyin MR görüntüsünden oluşan veri seti-2 ile model eğitilmiştir. 11 katmanlı modelimizde tümörün yakalanmasını üstün bir performans ile sağlayan farklı aşamalar bulunmaktadır. Bu aşamalar aşağıda açıklanmaktadır. Şekil 33, önerilen modelin diyagramını sunmaktadır.



Şekil 33. Önerilen ESA modeli

Resim özelliklerini algılamaktan sorumlu olan *evrişimli katman (convolution)* ESA'nın temel taşıdır. Evrişim katmanı girdi verileri üzerinde evrişim işlemini gerçekleştirir. Görüntüdeki düşük ve yüksek seviyeli özellikleri belirleyip çıkarmak için resme bazı filtreler uygular. Önerdiğimiz yeni ESA modelimiz bir evrişim katmanı ile başlar. Bu katman 64 filtrelidir ve  $3 \times 3$  filtre boyutuna sahiptir. Ağdaki uyumsuzluğu kontrol etmek için her evrişim katmanından sonra havuzlama katmanı kullanılmıştır. Birden fazla havuzlama yöntemi vardır fakat en popüler olanı *maksimum havuzlama (max pooling)* yöntemidir. Bu yöntemin kullanılmasıyla önemli bilgiler yok olmadan korunarak giriş verilerinin boyutsallığı azaltılmıştır. Daha sonra ise ESA'yı daha düzenli hale getirmek ve ağır kararlılığını artırmak için normalleştirme katmanı kullanılmıştır. *Toplu normalleştirme (batch normalization)*, ağır öğrenmesini hızlandırması, girdilerin normalleştirilmesi yoluyla bırakma oranını veya işleme katmanları arasındaki kaybolan verileri azaltması gibi avantajları söz konusudur. Bu sayede doğruluk ağ genelinde önemli ölçüde artırılmış olur.

Görüntülerde birden fazla farklı özellik bulunduğu ve modelin verimliliğini artırmak için, üçüncü, beşinci, yedinci ve dokuzuncu katmanlarda filtre sayıları değiştirilmiştir. Artırılan filtre sayılarıyla farklı görüntü özelliklerinin daha iyi algılanması sağlanmıştır. Bu katmanlarda da aynı aşamalar tekrar edilerek evrişim katmanından sonra maksimum havuzlama ve yığın normalleştirme katmanları kullanılmıştır. Bu işlem adımlarının yürütülmesinden sonra elde edilen matrisin tam

bağlantılı katmanında kullanılabilmesi için düzleştirilmesi gereklidir. Bunun için bir düzleştirme katmanı eklenmiştir. Böylece *tam bağlantılı (fully connected) katmanının* girdileri hazır olur.

ESA sinir ağı modelimizde düzleştirme katmanından sonra tam bağlantılı katman gelmektedir. Bu katman kendisinden önceki katmanın tüm alanlarına bağlı olduğu için tam bağlantılı katman olarak adlandırılmaktadır. Bu katman ESA modelinin son katmanıdır. Modelimize 3×3 boyutlu 1024 filtrelili tam bağlantı katmanı ekledik. Daha sonra ise modelimizin eğitimi aşamasında aşırı öğrenmeyi engellemek için *seyreltme katmanı (dropout)* kullandık. Bu katman rastgele seçilen belirli nöron setlerini eğitim aşamasında unutmaya (yok sayma) mantığına göre çalışmaktadır. Uygulanan denemeler sonrasında modelin ölçülen performansına bağlı olarak dropout değeri optimal 0.25 olarak belirlenmiştir. Dropout katmanından sonra 3×3 512 özellikli farklı bir tam bağlantılı katman daha eklenmiştir. Son katmanda çoklu sınıflandırma yapmak için, verilen girdilerin sınıfsal tahminini elde etmeyi sağlayan *softmax* fonksiyonu kullanılarak model tamamlanmaktadır. Bu aşamada giriş verileri; glioma, meningioma, pituitary ve tümör yok şeklinde sınıflara ayrılır.

Kodlarımızı iki farklı ortamda çalıştırdık, ilk olarak Python editöründe çalıştırdıktan sonra *Google Colab* platformunda çalıştırarak deneysel sonuçlarımızı bu platforma göre verdik. Tüm parametreler farklı veri bölümleriyle test edilerek optimum performans sağlayacak biçimde ayarlanmıştır. Modelde kullanılan hiper-parametreler ve değerleri ayrıntılarıyla Tablo 2’de sunulmaktadır.

**Tablo 2.** ESA modelimizde kullanılan hiper-parametre değerleri

Hiper-parametreler	Değer
Giriş aktivasyon fonksiyonu (Input activation function)	ReLU
Çıkış aktivasyon fonksiyonu (Output activation function)	Softmax
Kayıp (Loss)	Categorical crossentropy
Metrikler (Metrics)	Accuracy
Optimizasyon algoritması (Optimizer)	Adam
Tur sayısı (Epoch)	60
Seyreltme oranı (Dropout rate)	0.25
Öğrenme oranı (Initial learning rate)	0.001
Öğrenme oranı düşüşü (Learning rate decay)	0.0001
Veri yığın boyutu (Batch size)	32
Eğitim-test bölünmesi (Train-test split)	81.3%-18.7%

Bu çalışmada modelin oluşturulması aşamasında hangi katmanların kullanılacağı ve hangi bölümlere yerleştirileceğinin saptanması, kullanılan hiper-parametreler ve modelin parametreleri literatürde yer alan başarılı yöntemler incelenerek ve deneyler yapılarak belirlenmiştir. Ayrıca bu noktada deneyimlerimize dayanarak belirli iyileştirme çalışmaları yapılmış ve optimum performans elde edilmeye çalışılmıştır. Modelimizin optimize edicisi olarak *Adam* optimizasyon algoritması belirlenmiştir.

Modelin eğitim başarısına etki eden diğer parametrelere göz atarsak; *tur sayısının (epoch)* optimal olması gerekir, aksi durumda model öğrenme yerine ezber yapabilir veya ağırlıklar optimal olarak güncellenmeyebilir. Modelimizde optimal *tur sayısı* değeri 60 olarak belirlenmiştir. Kayıp fonksiyonu olarak *categorical\_crossentropy* kullanılmış ve ilk öğrenme oranı ise 0.001 olarak saptanmıştır. Modelimizin giriş aktivasyon fonksiyonu daha hızlı biçimde öğrenme gerçekleştiren *ReLU* fonksiyonudur. Çıkış aktivasyon fonksiyonu ise *Softmax*’dir. Softmax, 0-1 aralığında değerler

üretmek için belirli bir sınıfa ait olma olasılığını belirlemektedir. *Veri yığın boyutu (batch size)*, ise 32 olarak belirlenmiştir. Modelin performansını ölçen metrik, literatürde önemli bir değerlendirme kriteri olarak yeterli kabul gören *doğruluk (accuracy)* metriğidir. Modelin bir diğer önemli parametresi olarak, mevcut veri setinin %81.3'ü eğitim, kalan %18.7'si ise test için ayrılmıştır.

### 5.2.2. Değerlendirme Metrikleri

Geliştirilen modellerin başarı performansını ölçmek için doğru metriklerin seçilmesi önemli bir adımdır. Bu çalışmada önerilen modelin genel performans değerlendirmesini yapmak için doğruluk, kesinlik, geri çağırma, F1 puanı gibi iyi bilinen matrisler kullanılmıştır. Bu metrikler sınıflandırma çalışmalarında yaygın olarak kullanılmaktadır. Aşağıda yer alan *Karışıklık Matrisi* tablosu, bir sınıflandırma problemindeki gerçek ve tahmin edilen değerleri göstermektedir (Tablo 3).

**Tablo 3.** Karışıklık matrisi

		Tahmin	
		Doğru Negatif (True Negatives-TN)	Yanlış Pozitif (False Positives-FP)
Gerçek	Doğru Negatif (True Negatives-TN)	Doğru Negatif (True Negatives-TN)	Yanlış Pozitif (False Positives-FP)
	Yanlış Negatif (False Negatives-FN)	Yanlış Negatif (False Negatives-FN)	Doğru Pozitif (True Positives-TP)

Tablo 3'te yer alan terimleri kısaca açıklayacak olursak (Ay, 2020):

- ♦ *TP (True Positive)* — *Hastaya hasta demek.*
  - ♦ *FP (False Positive)* — *Hasta olmayana hasta demek.*
  - ♦ *TN (True Negative)* — *Hasta olmayana hasta değil demek.*
  - ♦ *FN (False Negative)* — *Hasta olana hasta değil demek.*
- *Doğruluk (Accuracy)*, bir modelin başarısını ölçmek için sıklıkla kullanılan bir ölçüdür. Doğru olarak sınıflandırılan örneklerin yüzdesidir. Modelin yeterliliğini ölçen en önemli metrik olan doğruluk hesaplaması aşağıda yer alan Denklem 6'da gösterilmektedir.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

- *Kesinlik (Precision)*, pozitif olarak tahminlenen değerlerin gerçekte kaçının pozitif olduğunu veren metriktir. Kesinlik hesaplaması aşağıda yer alan Denklem 7'de gösterilmektedir.

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

- *Duyarlılık (Recall)*, pozitif olarak tahmin etmemiz gereken değerlerin ne kadarını pozitif olarak tahmin ettiğimizi gösterir. Duyarlılık hesaplaması aşağıda yer alan Denklem 8’de gösterilmektedir.

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

- Bir testin doğruluğunun ölçüsünü ifade eden *F1 puanı* ise, kesinlik ve duyarlılığın harmonik ortalamasını verir. Alabileceği maksimum değer 1, mükemmel kesinlik ve duyarlılığı ifade ederken alabileceği minimum değer ise 0’dır. F1 puanı hesaplaması aşağıda yer alan Denklem 9’da gösterilmektedir.

$$F1\ Score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (9)$$

### 5.2.3. Deneysel Bulgular

Çalışmamız veri setindeki MR görüntülerini sınıflandıran derin verimli bir ESA modeli önermektedir. Bu sınıflar; meningioma, glioma, pituitary ve tümör yok şeklinde dört sınıftır. Öncelikle deneysel aşamaları gerçekleştirmek için gerekli tüm kütüphaneler içe aktarılmış ve deneyler gerçekleştirilmiştir (Şekil 34).

```
# Necessary imports
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Flatten, Conv2D, MaxPooling2D, Dropout
from tensorflow.keras.layers import BatchNormalization
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.optimizers import Adam, SGD
from tensorflow.keras.callbacks import EarlyStopping, ReduceLROnPlateau, ModelCheckpoint
import numpy as np
import os
import cv2
import matplotlib.pyplot as plt
import seaborn as sns
```

Şekil 34. Kütüphaneleri içe aktarma

Sıfırdan oluşturulan ESA modeli ile tümör tipleri sınıflara ayrılmıştır. Önerilen model, birden çok aşama ve deney dikkate alınarak doğrulanmıştır. Geliştirilen sistem yüksek sınıflandırma doğruluğu göstermiştir. Modelin performansı, sistemin sağlamlığını belirlemek için diğer ölçütler kullanılarak da değerlendirilmiştir. Modelimizden elde edilen performans değerleri aşağıda yer alan Tablo 4’te gösterilmektedir.

Tablo 4. Önerilen ESA modelinin performans ölçütleri

Tümör sınıfı	Kesinlik	Duyarlılık	F1-skoru	Ortalama doğruluk %
Glioma	0.99	1.00	1.00	99.76
Meningioma	1.00	0.99	1.00	
Pituitary	1.00	1.00	1.00	
No tumor	1.00	1.00	1.00	

Tablo 4’te yer alan performans değerleri karışıklık matrisi ile analiz edilmiştir. Çalışmanın ilerleyen kısımlarında gerçek değerler ve tahmin edilen değerler ile oluşturulan karışıklık matrisine yer verilmektedir. Çalışmamızın tüm performans metrikleri tutarlı yüksek değerler içermektedir. Modelimizin yeterliliğini ölçen doğruluk değeri ise 99.76% olarak bulunmuştur.

Çalışmamızın bir sonraki adımında geliştirdiğimiz sistemin performans başarısını ölçmek için veri seti-3 ile modelimizi eğittik. 3264 görüntüden oluşan dört sınıflı veri kümesi ile eğitilen model yüksek başarı göstermiştir. Bu veri seti ile modelin sınıflandırma başarısı %97.45’tir. Bu oran modelin sağlam ve etkili olduğunu ortaya koyan bir başka sonuçtur. Modelimizin farklı deneyler üzerinde de oldukça tatmin edici bir performans gösterdiği açıktır (Tablo 5).

**Tablo 5.** Farklı veri kümelerindeki performans doğruluk değerleri

Veri setleri	Method	Doğruluk%
Veri seti-2	Önerilen model-ESA	99.76
Veri seti-3	Önerilen model-ESA	97.45

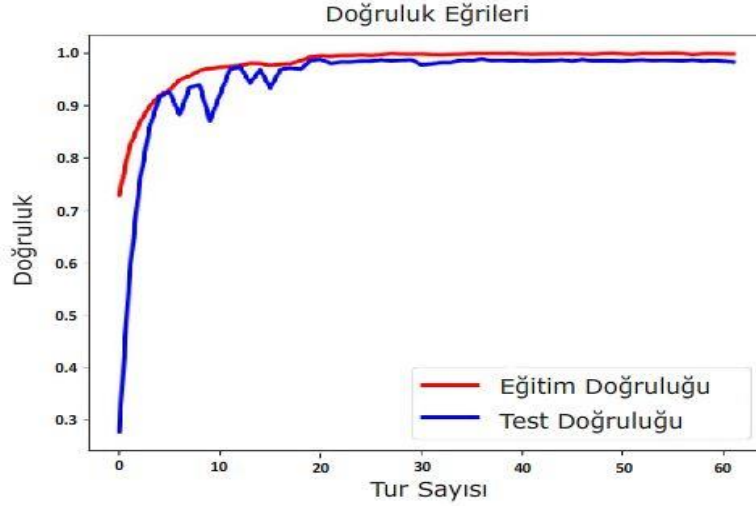
### 5.2.3.1. Modelin Sağlamlığını ve Genelleme Yeteneğini Doğrulama

Modelin genellenebilir olması modelin etkin olması açısından ön koşullardan biridir. Sıfırdan oluşturduğumuz modelimizin genelleştirme kabiliyetini doğrulamak için iki ayrı veri setinin eğitim ve test aşamaları ayrı bölünme oranları ile denenmiştir (9:1, 8:2, 7:3). Eğitim ve veri kümesi olarak ayrı oranlarda bölünmenin performansı çok fazla değiştirmedeğini gözlemledik. Bunun yanında, aynı veri seti farklı katman sayıları ile oluşturulan özel ESA’lar ile eğitilmiş ve sonuçlar incelenmiştir. Modele ait deneysel sonuçlardan en yüksek performans çıktılarını sağlayan değerler alınmış ve bu çalışmada sunulmuştur. Ayrıca farklı sınıflandırma fonksiyonları denenmiştir. Klasik ESA tabanlı modellerde *softmax* ve *sigmoid* fonksiyonları sınıflandırmada kullanılan aktivasyon fonksiyonlarıdır. Buna ek olarak MÖ sınıflandırıcıları da sınıflandırma probleminde kullanılabilir (Destek Vektör Makinesi, Karar Ağaçları, Naïve Bayes vd). Çalışmamızda makine öğrenmesi sınıflandırıcılarından, en yakın komşuların sayısı ve mesafe ölçüsünü kullanan k-NN seçilerek yapılan sınıflandırmada derin ESA özelliklerinde k-NN ile doğruluğu %98.21 olarak bulduk. Yapılan deneyler sonucunda çok sınıflı sınıflandırmada *softmax*’in diğer sınıflandırıcılar arasında en iyi performansı gösterdiği belirlenmiş ve deneysel sonuçlarda verilmiştir (Tablo 6).

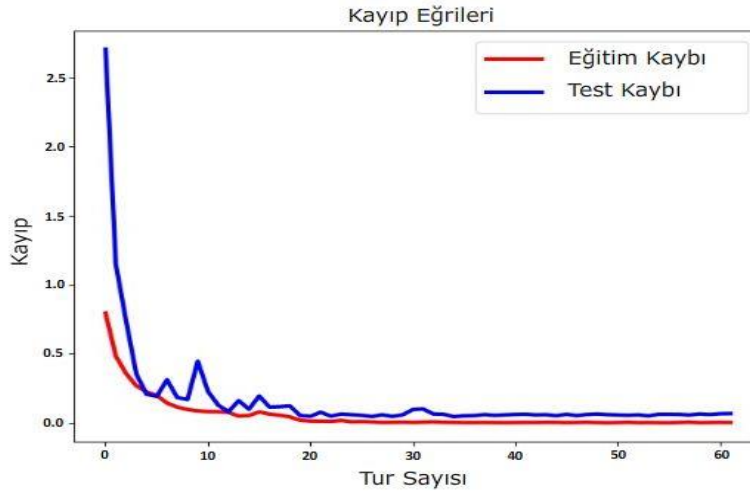
**Tablo 6.** Farklı sınıflandırıcıların doğruluk oranları

Model	Sınıflandırıcı	Doğruluk %
ESA	k-NN	98.21
	Softmax	99.76

En uygun hiper-parametrelerin seçimi ve bunların test edilmesi sağlam bir model oluşturmak için önemli adımlardan biridir. Bu çalışmada önerilen ESA modelimiz birçok yöntem denendikten sonra son halini almıştır. Şekil 35’te, geliştirilen yeni ESA modelinin 60 tur sayısı (epoch) için eğitim/test doğruluk ve eğitim/test kayıp grafikleri verilmiştir.



(a) Eğitim ve test doğruluk eğrisi

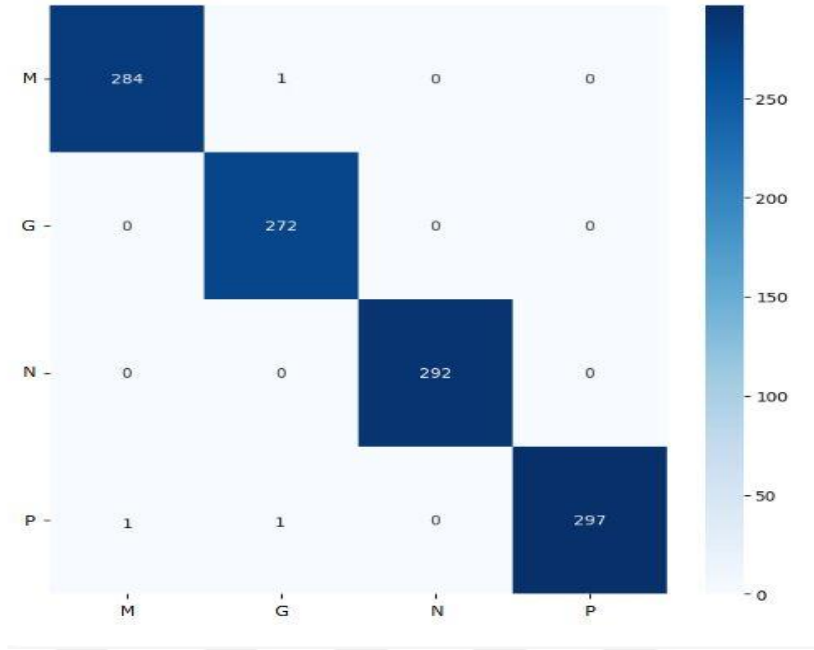


(b) Eğitim ve test kayıp eğrisi

**Şekil 35.** Eğitim ve test eğrilik grafikleri

Yatay eksen modelin tur sayısını (epoch) dikey eksen ise öğrenme oranını vermektedir (Şekil 35). Modelin adım adım öğrenme sürecini gösteren öğrenme eğrileri incelenerek modelin aşırı uyum durumu gösterip göstermediği belirlenebilir. Ayrıca veri seti ile model arasındaki uyumluluk da bu eğriler aracılığı ile yorumlanabilir. Şekil 35 (a)'ya bakıldığında, hem test hem de eğitim doğruluk eğrileri, tur sayısı arttıkça yükselen bir eğim göstermektedir. Belli bir tur sayısına kadar artış gösteren doğruluk değerinde belli bir sayıdan sonra çok küçük değişiklikler gerçekleşmektedir. Modelin eğitiminin bu aşamada gerçekleştiği söylenebilir.

Şekil 35 (b)'de yer alan kayıp eğrisi ise hata oranındaki düşüşü göstermektedir. Grafik incelendiğinde, ESA tabanlı modelin tur sayısına göre eğitim sürecinin ve ağıın öğrenme performansının iyi bir öğrenme oranında olduğu görülmektedir. Tur sayısı arttıkça kayıp değeri azalır, verilen eğitim seti ile doğruluk oranı artar ve öğrenme gerçekleşir. Şekilde 35 (b)'de görüldüğü gibi, belli bir tur sayısından (epoch) sonra kayıp değeri değişmemektedir. Şekil 36'da ise yüksek doğruluk değeri elde edilen derin ESA modeline ait karışıklık matrisi verilmiştir.



Şekil 36. Modelin karışıklık matrisi

Beyin tümörü sınıflandırma sistemimizin performansını incelemek için karışıklık matrisini kullandık. Karışıklık matrisi, doğru ve yanlış sınıflandırmaları şekilsel bir tablo ile özetlemektedir. M, G, N, P sırası ile Meningioma, Glioma, No-Tumor ve Pituitary tümörünü temsil etmektedir (Şekil 36). Modelin değerlendirilmesi için matris üzerinde ayrıntılı inceleme yapılması önemlidir. Önerdiğimiz modele ait karışıklık matrisini incelediğimizde, test için ayrılmış 285 Meningioma beyin tümörü görüntüsünden 284'ünün çarpıcı bir şekilde model tarafından doğru tahmin edildiği görülmektedir. Bununla birlikte, 274 Glioma tümör görüntüsünden 272 görüntü Glioma olarak doğru sınıflandırılmıştır. Karışıklık matrisine göre, tümör içermeyen görüntüler tümör yok olarak yüksek doğrulukla tespit edilmiştir. Benzer şekilde, Pituitary tümör tipine ait görüntülerin de yüksek doğrulukla sınıflandırıldığı görülmektedir.

#### 5.2.4. Önerilen Modelin Kanonik ESA Mimarilerinden Farklılıkları

Önerdiğimiz model, geleneksel kanonik ESA yapılarından farklı olarak optimize edilmiş katman düzeni, gelişmiş evrişim teknikleri ve modern normalizasyon yöntemleriyle tasarlanmıştır. Bu değişiklikler yalnızca modelin doğruluğunu artırmakla kalmaz, aynı zamanda daha hızlı ve daha verimli çalışmasını da sağlar. Aşağıda geliştirdiğimiz modelin mimari farklılıkları maddeler halinde verilmiştir.

- Geleneksel ESA modelleri genellikle 3-5 evrişim katmanına sahiptir. Önerdiğimiz model 9 evrişim katmanı içerir ve her biri farklı filtre boyutları ve kanal numaralarıyla optimize edilmiştir.
- Çalışma, Adam optimizasyon algoritmasına ek olarak, SGD ve RMSprop gibi modern optimizasyon teknikleriyle test edilmiştir. RMSprop optimizasyonu, SGD'ye kıyasla daha kararlı bir öğrenme süreci sağlayarak doğruluk oranını artırmıştır.
- Öğrenme oranı ayarlamalarıyla modelin aşırı uyum sağlama riski azaltılmıştır.

### 5.2.5. Ablasyon Çalışması

Modelimizin doğruluğunu artıran her bir bileşenin önemini vurgulamak için bir ablasyon çalışması yürütüldü. Aşağıda yer alan Tablo 7, modelin belirli bileşenleri çıkarıldığında ve farklı parametreler denendiğinde doğruluğun nasıl değiştiğini göstermektedir.

**Tablo 7.** ESA modelde farklı hiper parametrelerin kullanılması

Model yapılandırması	Doğruluk (%)
Önerilen tam model	<b>99.76</b>
Standart ESA (3 katman, ReLU, MaxPooling)	92.34
ReLU yerine Sigmoid fonksiyonu	95.32
Softmax yerine Sigmoid fonksiyonu	97.21
Adam optimizasyon algoritması yerine SGD	96.12
Adam optimizasyon algoritması yerine RMSprop	98.45
Tur sayısı 60 yerine 30	97.89
Öğrenme oranı 0.001 yerine 0.0001	99.12
Veri yığın boyutu 32 yerine 16	98.41
Veri yığın boyutu 32 yerine 64	98.74
Bölünme oranı 70%-30%	98.91

Tablo 7, modelin hiper-parametre ayarlamalarına verdiği yanıtı açıkça göstermektedir. Önerdiğimiz modelin %99.76 doğrulukla en iyi performansı sağladığı görülmektedir. Standart ESA modeli yalnızca üç katmanla sınırlı olduğunda, doğruluk %92.34'e düşmektedir; bu da daha derin modellerin daha iyi genelleştirilebileceğini göstermektedir. Sigmoid yerine ReLU kullanılması model doğruluğunu artırırken, optimizasyon algoritması olarak Adam yerine SGD kullanıldığında doğruluğun %96.12'ye düştüğü görülmektedir.

Öğrenme oranı 0.0001 ve tur sayısı 30 olarak belirlendiğinde, model doğruluğu sırasıyla %99.12'ye ve %97.89'a düşmektedir. Ayrıca veri yığını boyutu 16'ya düşürüldüğünde doğruluk %98.41 olarak ölçülürken, 64'e çıkarıldığında %98.74 olarak ölçülmektedir. Eğitim-test bölünmesi %70-%30 olarak değiştirildiğinde doğruluk %98.91'e düşmüştür; bu da daha fazla test verisinin model performansı üzerinde çok az etkisi olduğunu göstermektedir. Tablo 7'de yer alan sonuçlara göre, titiz hiper-parametre ayarlamasıyla en iyi model yapılandırmasını elde ettiğimizi söyleyebiliriz.

### 5.2.6. k-Katlı Çapraz Doğrulama

*k-Katlı Çapraz Doğrulama*, modelin hem öğrenme kabiliyetini hem de genelleme performansını ölçmek için etkili bir yöntemdir, çünkü model tüm veri seti üzerinde hem eğitim hem test aşamasında farklı örnekler görür. Çapraz doğrulama testinde, veri seti farklı katmanlara bölündü ve model her katmanda eğitildi ve test edildi. Sonuçlar aşağıda yer alan Tablo 8'de sunulmaktadır.

**Tablo 8.** k-Katlı çapraz doğrulama sonuçları

Kat sayısı (k)	Ortalama doğruluk (%)	Standart sapma
k=3	99.42	0.21
k=5	99.56	0.18
k=10	99.61	0.14

Tablo 8'e göre modelimizin farklı veri kümeleri üzerinde kararlı bir doğruluk oranı sağladığını ve yüksek genelleştirilebilirliğe sahip olduğunu söyleyebiliriz. Modelin farklı katman sayıları (k) ile test edilmesi sonucunda en yüksek doğruluk oranı %99.61 ile k=10 için elde edilmiştir. Katman sayısı arttıkça modelin genelleme yeteneği ve doğruluk oranının arttığı, ancak aşırı yüksek katman sayılarında hesaplama maliyetinin artabildiği belirlenmiştir. Standart sapma değerlerine bakıldığında ise en düşük standart sapma (0.14) değeri k=10 için elde edilmiş ve modelin daha kararlı sonuçlar ürettiği gözlenmiştir.

Özellikle k=3 ile karşılaştırıldığında doğruluk oranının %99.42 olduğu ancak standart sapma değerinin %0.21 ile en yüksek olduğu anlaşılmaktadır. Bu, modelin daha az stabil çalıştığını ve sonuçların daha fazla değişkenliğe sahip olabileceğini göstermektedir. k=5 için doğruluk %99.56 iken standart sapma %0.18 ile orta seviyede kalmıştır. Genel olarak değerlendirildiğinde en yüksek doğruluğu ve en düşük değişkenliği sunduğu için k=10'un en optimum seçim olduğu söylenebilir.

### 5.2.7. İlgili Çalışmalarla Karşılaştırma

Beyin tümörlerinin teşhisi ve sınıflandırılması probleminde geliştirdiğimiz yöntemin performansını diğer mevcut yöntemlerle karşılaştırdık. Burada karşılaştırma, prestijli dergilerde yayınlanan farklı derin öğrenme modellerinden yüksek doğruluk sınıflandırması gösteren makale çalışmalarının sonuçlarıyla, önerdiğimiz modelin sonuçlarının karşılaştırılması yoluyla yapılmıştır. Karşılaştırmalı sonuçlar aşağıda yer alan Tablo 9 ile özetlenmektedir.

**Tablo 9.** Veri seti 3'e dayalı beyin tümörleri üzerine yapılan çalışmaların karşılaştırmalı incelemesi

Referans	Metot	Doğruluk %
Vankdothu vd. (2022)	ESA-LSTM	92.00
Deepak ve Amer (2021)	ESA ve DVM	90.21
Badža ve Barjaktarović (2020)	ESA	89.45
Abiwinanda vd. (2018)	ESA	88.68
Sultan vd. (2019)	DSA	90.21
Ayadi vd. (2021)	ESA	95.71
Aslan (2024)	ESA-LSTM	98.10
Kumar vd. (2021)	ResNet-50 ve Küresel Ortalama Havuzlama	95.10
Sharma (2023)	ESA	89.00
Önerdiğimiz model (Veri seti-3)	ESA	97.45
Önerdiğimiz model (Veri seti-2)	ESA	99.76

Bu tablo beyin tümörlerinin sınıflandırılması üzerine yapılmış çeşitli çalışmaları ve önerilen yöntemlerin başarı oranlarını göstermektedir. Çalışmaların çoğunda geleneksel sinir ağları ve derin öğrenme teknikleri kullanılmıştır. Ayrıca, bazı çalışmalarda ESA ve LSTM, Destek Vektör Makineleri (DVM) ve Derin Sinir Ağları (DSA) gibi hibrit yöntemler tercih edilmiştir. Tablo 9'a göre beyin tümörü sınıflandırma yöntemlerinin başarı oranları genel olarak yüksektir. Örneğin Vankdothu vd. (2022)'nin çalışmasında %95.71 doğruluk oranı elde edilirken, Kumar vd. (2021)'nin çalışmasında %95.10 doğruluk oranı elde edilmiştir. Ancak, önerilen model (Veri seti-3) %97.45 başarı oranıyla en yüksek doğruluk oranına ulaşmış ve özellikle Veri seti-2'de %99.76 ile yüksek başarı oranı elde edilmiştir. Bu da önerilen modelin mevcut literatürdeki çoğu yöntemden daha iyi performans gösterdiğini ve beyin tümörü sınıflandırmasında yüksek doğruluk sağladığını göstermektedir.

Çeşitli çalışmalarda kullanılan yöntemlerin doğrulukları arasındaki farklılıklar, model seçiminin ne kadar kritik olduğunu bir kez daha ortaya koymaktadır. Önerilen modelin yüksek

doğruluk oranı, modelin yapısal tasarımının, hiper-parametrelerinin ve eğitim sürecinin etkili bir şekilde optimize edildiğini göstermektedir. Ayrıca, ESA tabanlı yöntemlerin genellikle görsel verilerle daha verimli çalıştığı ve bu tür DÖ modellerinin beyin tümörleri gibi tıbbi görüntülerin analizinde yüksek başarı sağladığı gözlemlenmiştir. Bu, önerilen modelin seçilen teknik açısından doğru bir seçim olduğunu desteklemektedir. Modelin başarısı, yalnızca kullanılan yöntemin kalitesiyle değil, aynı zamanda üzerinde eğitildiği veri kümesinin kalitesi ve çeşitliliğiyle de doğrudan ilişkilidir. Örneğin, Veri seti-2 ve Veri seti-3'te farklı doğruluk oranlarının bulunması, veri kümelerindeki görüntülerin zorluk seviyesi, veri kümesinin boyutu ve çeşitliliği gibi faktörlerin modelin performansını etkileyebileceğini göstermektedir. Bu noktada, veri kümelerinin genelleme yeteneği ve aşırı uyumu önlemek için yapılan iyileştirmeler de oldukça önemlidir. Yüksek doğruluk oranlarının dengeli, doğru etiketlenmiş ve yeterince büyük veri kümelerinden kaynaklanabileceği unutulmamalıdır.

Tablo 9, beyin tümörü sınıflandırması üzerine yapılan önceki çalışmaları ve önerilen modelimizin üstün performansını açıkça göstermektedir. Önerilen modelin yüksek doğruluk oranları, bu alandaki araştırmaların ilerlemesine katkıda bulunacağını ve gelecekteki uygulamalarda etkili bir şekilde kullanılabilirliğini göstermektedir. Ayrıca, modelin diğer yöntemlere kıyasla daha iyi genelleme potansiyeline sahip olduğu söylenebilir. Modelin sağlamlığı açısından, önerilen modelin sürekli olarak yüksek doğruluk oranları, gürültüye ve değişkenliğe karşı sağlam bir yapıya sahip olduğunu da göstermektedir. Önerilen model, mevcut literatürdeki en iyi sonuçları sunarak yenilikçi ve etkili bir çözüm sunmaktadır. Modelin yüksek doğruluk oranı; gelişmiş optimizasyon teknikleri, güçlü ağ mimarisi ve etkili veri işleme stratejileriyle desteklenmekte ve gelecekteki araştırmalar için önemli bir referans noktası olabileceğini kanıtlamaktadır.

### **5.3. Transformatör Tabanlı Derin Öğrenme Modellerinde Beyin MR Görüntü Sınıflandırmasının Başarısına Damıtma Tekniğinin Katkısına İlişkin Geliştirilen Model ve Deneysel Bulgular**

#### **5.3.1. Veri Seti ve Uygulama Detayları**

Çalışmanın eğitim ve test aşamalarında beyin MR görüntülerini içeren açık erişimli bir veri seti olan, beyin tümörü sınıflandırmasını içeren veri seti-3 kullanılmıştır. Veri setinde toplam 3264 beyin MR görüntüsü bulunmaktadır, bunlardan 2870'i eğitim, 394'ü ise test alt kümelerine ayrılmıştır. Veri seti-3, çok sınıflı bir sınıflandırma problemine çözüm aramaktadır. Veri seti, üç farklı beyin tümörü türü ve tümör olmayan görüntüler olmak üzere dört farklı sınıfa ait görüntüler içermektedir. Bunlar; glioma tümörü, menenjiyom tümörü, tümör yok ve hipofiz tümörüdür.

Bu çalışmada veri seti-3, düşük sayıda veri seti kullanımında transformatör modellerin başarısını değerlendirmek amacıyla seçilmiştir. Tıbbi alanda görsel veri seti seçilmesinin nedeni, gerçek dünyada tıbbi görüntülere ulaşmanın zor olmasıdır. İnsan hayatını olumsuz etkileyen ve ölüme neden olabilen birçok hastalık tıbbi görüntüler kullanılarak teşhis edilebilir. Ancak transformatör tabanlı DÖ modellerinin en büyük dezavantajı, çok sayıda eğitim verisiyle yüksek başarı oranlarına ulaşabilmesidir. Bu çalışmada transformatör modellerinin bu dezavantajının damıtma belirteçleri gibi çözümlerle çözümlenip çözülemeyeceği incelenmiştir. Ayrıca SARS (Chan vd., 2004), Covid (Akkuzu vd., 2023), Mpox (Aden vd., 2023) gibi salgın hastalıklar, DÖ'ye dayalı hastalık teşhis süreçlerinin veri seti toplama süreçlerine toleranslı olmaması gerektiğini göstermiştir.

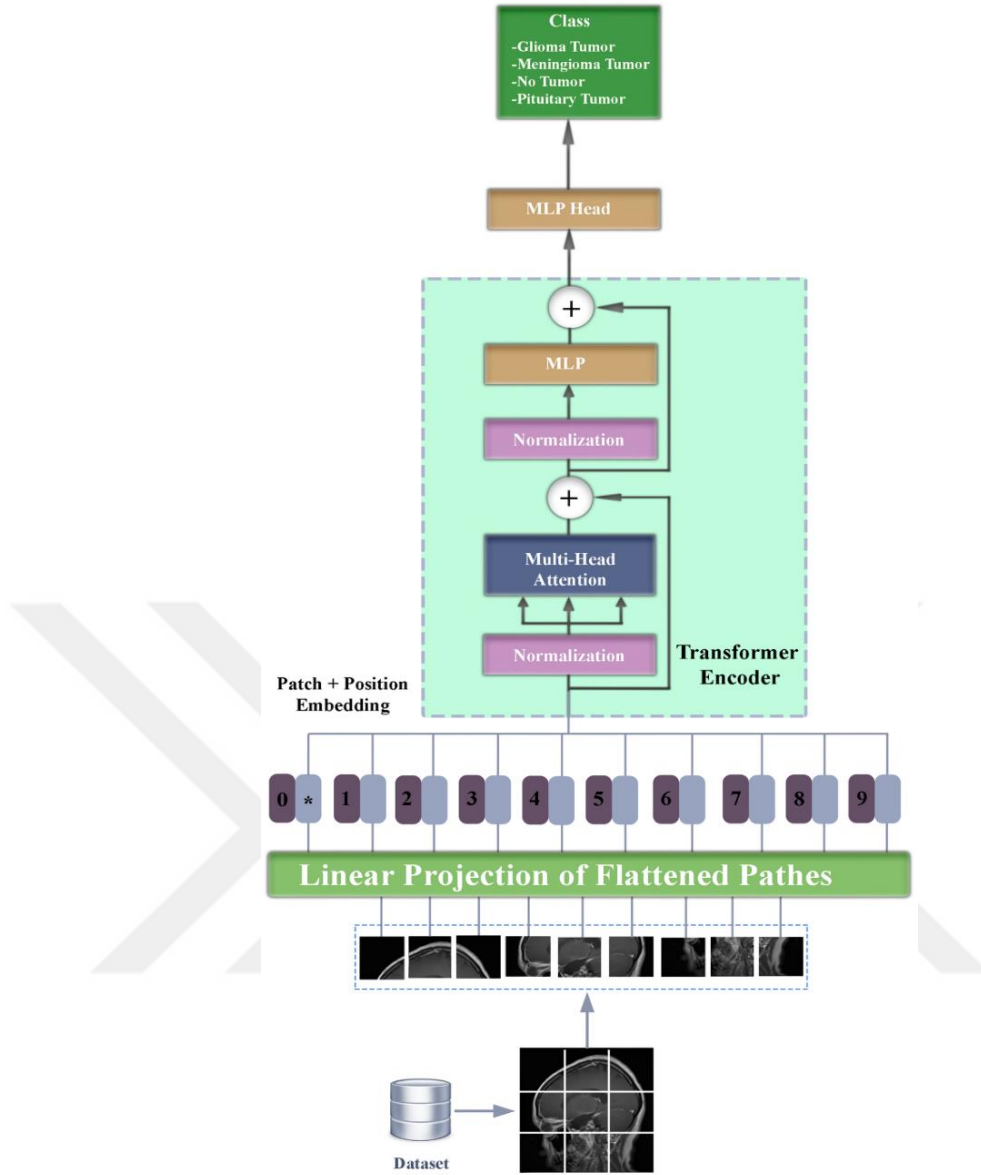
Bu nedenlerle, düşük sayıda veri seti kullanılarak transformatör modelleriyle yüksek başarı elde etmek önemlidir.

### 5.3.2. Ön İşleme Adımları

Veri seti-3, çalışmada kullanılacak DÖ modellerine girdi olarak verilmeden önce, daha verimli ve standartlaştırılmış bir girdi sağlamak için bazı basit ön işlemlere tabi tutulmuştur. Görüntüler ilk olarak 384x384'e yeniden ölçeklendirilmiştir. Bu işleme adımı, farklı boyutlardaki görüntülerin standart bir ölçeğe getirilmesini ve modele uygulanmasını sağlar. Bir sonraki adımda, 15 dereceye kadar *RandomHorizontalFlip* ve *RandomRotation* uygulanmıştır. Bu adım, modeli küçük açışal sapmalara karşı dayanıklı hale getirir. Bir sonraki adımda, görüntüler tensöre dönüştürülür. Görüntülerdeki her bir piksel, 0 ile 1 arasında bir değere ayarlanır. Son aşama olan normalizasyon aşamasında ise görüntüler, görüntülerden hesaplanan ortalama ve standart sapma değerleri kullanılarak normalleştirilir. Bu işlem, görüntü verilerinin her bir kanalın aritmetik ortalamasına ve standart sapmasına göre ölçeklenmesiyle modelin daha kararlı bir şekilde öğrenmesini sağlar.

### 5.3.3. Görüntü Dönüştürücü (ViT)

Geleneksel ESA'lardaki filtre dolanıklık işleminin aksine ViT modeli, görüntüleri bir dikkat mekanizması kullanarak işler. Modelin ilk adımında, görüntü eşit büyüklükteki yamalar halinde bölünür. Yamalar, modelin temel işlem birimleridir. Daha sonra her yama, doğrusal projeksiyon katmanında özellik vektörlerine dönüştürülür. Bir sonraki adımda, her yamaya, uzamsal bilgilerini korumak için konum vektörleri eklenir. Daha sonra, yamalar sırasıyla öz-dikkat katmanından geçirilir. Öz-dikkat, yamaların diğer yamalarla ilişkisini ve uzun mesafeli bağımlılıklarını hesaplar. Öz-dikkat katmanı birden çok kez uygulanarak, özellikler birden çok hesaplama yapılarak daha iyi öğrenilebilir. Özellik vektörleri, öz-dikkat katmanının çıktılarının ileri beslemeli ağ tarafından işlenmesiyle sonlandırılır. Son aşamada, modele eklenen kod çözücüyle elde edilen gösterimler, sınıf etiketlerini tahmin etmek için kullanılır. Açıklanan görüntü dönüştürücü modelinin blok diyagramı Şekil 37'de verilmiştir.



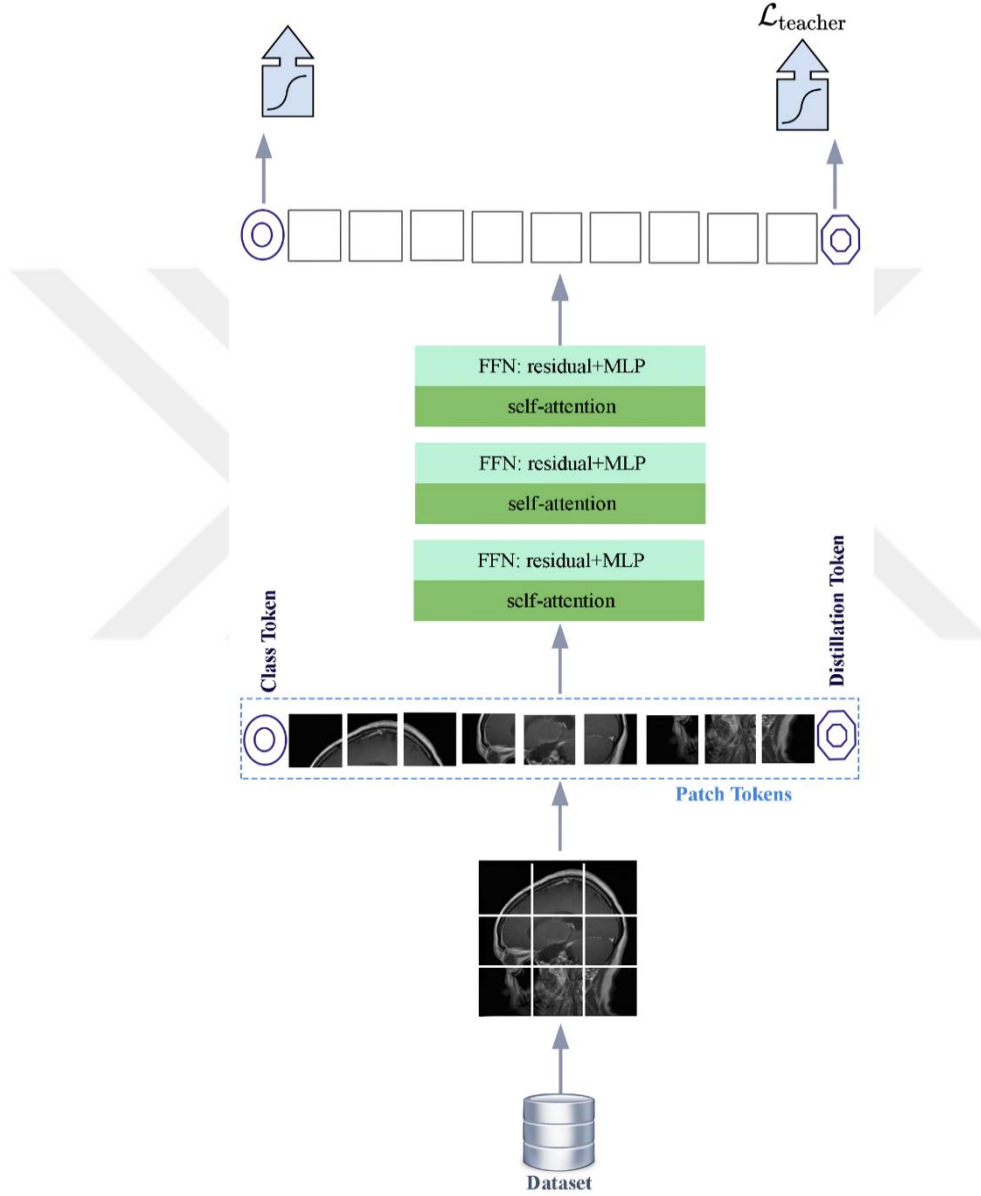
Şekil 37. Görüntü dönüştürücü (ViT) model diyagramı

ViT modelinin önemli avantajlarını tam olarak gerçekleştirebilmesi için büyük miktarda veriyle çalışması gerektiği bilinen bir gerçektir. Küçük ve dengesiz veri kümeleriyle çalışmak modelin başarısını olumsuz etkileyebilir. Ayrıca model, dikkat mekanizması nedeniyle büyük miktarda bellek kullanır. Yüksek bellek kullanımı, sınırlı kaynaklarla veri kümesini eğitmeyi zorlaştırır.

#### 5.3.4. Damıtılmış Veri Etkili Görüntü Dönüştürücü (Distilled Data-Efficient Image Transformer-DeiT)

DeiT, düşük sayıda görüntüye sahip veri kümelerinde yüksek performans elde etmeye odaklanan bir dönüştürücü tabanlı derin öğrenme modelidir (Touvron vd., 2021). DeiT, bir damıtma belirteci ile zenginleştirilmiş ViT modelinin bir türevidir (Jalalifar ve Sadeghi-Naini, 2022). DeiT, sınırlı veriye sahip tıbbi görüntüleme, otonom araçlar ve güvenlik sistemleri gibi alanlarda yüksek başarı elde edebilen bir modeldir.

Dönüştürücü tabanlı modellerin temel dezavantajı, eğitim sırasında büyük veri kümeleri gerektirmeleridir. DeiT modeli, bilgi damıtmasını kullanarak yüksek veri gereksinimini azaltır (Yin vd., 2022). DeiT modelinde kullanılan damıtma, bilgi damıtması olarak çalışır. Bilgi damıtması, gerçek hayattaki bir öğretmen-öğrenci modeline dayanır. Daha büyük model, öğretmen modeli, bilgileri daha küçük modele, öğrenci modeline aktarır. Öğretmen modelinde, modelin daha küçük verilerle öğrenmesini sağlayan büyük bir model olan ESA kullanılır. Bu avantajlar, modelin eğitimi sırasında eğitim maliyetlerini ve depolama kapasitesi ihtiyacını dolaylı olarak ortadan kaldırır (Barulina vd., 2022). DeiT modelinin blog diyagramı Şekil 38’de yer almaktadır.



Şekil 38. Damıtılmış veri etkili görüntü dönüştürücü (DeiT) model diyagramı

Derin öğrenme modellerinde eğitim sırasında bilgi damıtımı Hilton ve arkadaşları tarafından önerilmiştir (Hinton vd., 2015). Bilgi damıtımı, öğrenci adı verilen küçük bir modelin bilgisinin, öğretmen adı verilen büyük bir modeli taklit ederek sıkıştırılması işlemidir. Yumuşak ve sert adı verilen farklı bilgi damıtma versiyonları vardır. Bilgi damıtma yöntemleri arasındaki temel fark, bilginin öğrenci modeline nasıl aktarıldığıdır (Alotaibi vd., 2023). Yumuşak damıtmada, öğretmen

modeli istatistiksel bir dağılım çıktısı verir. Sert damıtmada, modelin çıktısı tek bir etiketten oluşur (Gou vd., 2021). DeiT, düşük verilerle yüksek başarıya ulaşmayı amaçlayan bir model olduğundan, modelde sert bilgi damıtma yöntemi kullanılmıştır. DeiT modelinde kullanılan sert bilgi damıtmanın matematiksel gösterimi Denklem 10'da verilmiştir.

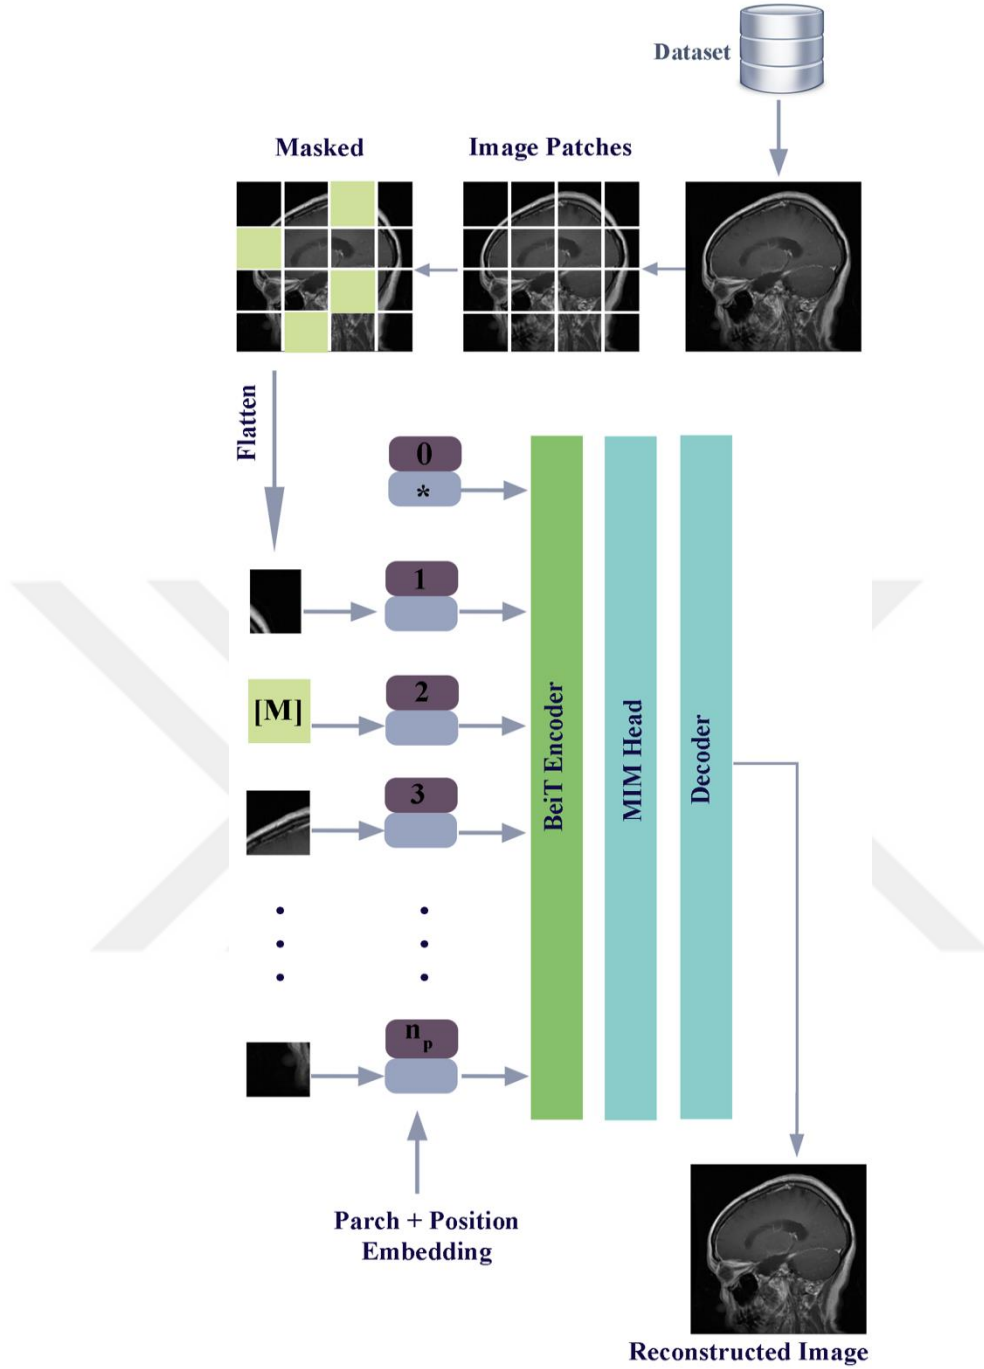
$$\mathcal{L}_{\text{global}}^{\text{HardDistill}} = \frac{1}{2} \mathcal{L}_{\text{CE}}(\psi(Z_s), y) + \frac{1}{2} \mathcal{L}_{\text{CE}}(\psi(Z_s), y_t) \quad (10)$$

Yukarıdaki denklemde sırasıyla,  $\psi$  =Softmax,  $\mathcal{L}_{\text{CE}}$  = çapraz entropi kaybı,  $Z_s$ = öğrencinin lojitleleri,  $y$ =temel gerçek,  $y_t$ =öğretmenin tahmin ettiği etiketleri temsil eder. Sert damıtma formül denklemi temel olarak iki bölümden oluşur. Formülün ilk bölümü, modelin öngörülerini ile gerçek etiketler arasındaki *Çapraz Entropi* kaybı olarak ifade edilebilir. Bu bileşen, model öngörülerini ile gerçek sınıf etiketleri arasındaki uyumsuzluğun bir ölçüsüdür. Formülün ikinci bölümü, öğrenci modelinin öngörülerini ile öğretmen modeli tarafından üretilen etiketler arasındaki *Çapraz Entropi* kaybıdır. Bu ölçüm temel olarak öğrenci modeli tarafından üretilen sonuçları, öğretmen modeli tarafından üretilen sonuçlara yaklaştırmak için kullanılır. Formülün her iki tarafına  $\frac{1}{2}$  katsayısı eklenerek, eğitim süresince öğrenci modelinin hem gerçek etiketlerden hem de öğretmen modelinin yönlendirmelerinden eşit şekilde etkilenmesi sağlanmaktadır.

### 5.3.5. Bert Görüntü Dönüştürücülerinin Ön Eğitimi (Bert Pre-Training of Image Transformers-BeiT)

BeiT, görüntü sınıflandırma, segmentasyon ve görüntülerden özellik çıkarma gibi bilgisayarlı görme uygulamalarında kullanılan transformatör tabanlı derin öğrenme modelidir (Bao vd., 2021). Görüntüler üzerinde doğal dil işleme alanında oldukça başarılı sonuçlar elde etmiş BERT modelinin yeterliliklerinin kullanılmasına olanak sağlayan mimari Microsoft Research tarafından geliştirilmiştir. BeiT, kullandığı ön eğitim stratejisiyle ViT modelinden ayrılmaktadır. Doğal dil işlemede sıklıkla kullanılan Maskelenmiş Dil Modelleme (MDM) tekniğine benzeyen Maskelenmiş Görüntü Modelleme (MGM) tekniği, modeli diğer transformatör tabanlı modellerden ayıran önemli bir yeniliktir. MGM tekniğinde görüntülerin rastgele seçilen yamaları maskelenmekte ve daha sonra bu maskelenmiş parçalar model tarafından tahminlerde kullanılmaktadır (Nhut vd., 2024).

BeiT modeli, etiketlenmemiş veriler kullanarak önceden eğitilebilir. Bu yetenek, modeli daha az etiketli verilerle eğitim ve test süreçlerinde daha başarılı hale getirir. Esnek bir model olan BeiT, sınıflandırma, segmentasyon, nesne algılama ve görüntülerden özellik çıkarma gibi birçok zorlu görevde kullanılabilir. Transformatör tabanlı bir model olduğundan, yüksek hesaplama gücü ve daha fazla eğitim süresi gerektirebilir. MGM tekniği ekstra veri ön işleme adımları eklediğinden, diğer transformatör tabanlı modellere kıyasla modele ekstra hesaplama yükü getirir (Rajesh vd., 2024). BeiT modelinin blog diyagramı Şekil 39'da yer almaktadır.



Şekil 39. BERT görüntü dönüştürücülerinin ön eğitimi (BeiT) model diyagramı

BeiT modelinde, bilgi damıtma belirteci yöntemi kullanılarak modelin öğrenme hızı artırılmış ve performansı iyileştirilmiştir. Damıtma sürecinde bilgi, daha güçlü olan öğretmen modelinden diğer modele, öğrenci modeline aktarılır. BeiT modelinde kullanılan özel bilgi damıtma yöntemi, öğretmen modelinin token tabanlı çıktıları ile öğrenci modelinin token tabanlı çıktıları arasındaki benzerlikleri optimize eder. Bu sayede öğrenci modeli daha hızlı ve yüksek performanslı bir yapıya kavuşmuştur.

BeiT modelinin aşamalarının açıklandığı Şekil 39'a göre BeiT modeli, görüntülerin 16x16 boyutlarına bölünmesiyle başlar. Bu aşamada, 224x224 boyutlarındaki bir görüntü toplamda 196 parçaya bölünür. Parçalanma sayesinde görüntünün yama adı verilen daha küçük parçaları üzerinde

işlemler gerçekleştirilir. Pozisyon yerleşimleri bir sonraki adımda yamalara eklenir. Yamalar arasındaki ilişki, kodlayıcı-kod çözücü mekanizmasında çok başlı dikkat ve öz dikkat kullanılarak öğrenilir (Kucukkulahli ve Kabakus, 2024). Maskeleye, görüntünün bazı rastgele yamalarına uygulanır. Bu, görüntünün maskelenmiş kısımlarının tahmin edilmeye çalışıldığı anlamına gelir. MGM tekniğinde önemli olan, maskelenmiş alanları doğru bir şekilde tahmin etmek için diğer yamalardan gelen bilgilerin etkili bir şekilde kullanılmasıdır. Modelde maskelenmiş parçaların görüntüye geri getirilmesine yeniden yapılandırma denir.

Yeniden yapılandırma aşamasında VQ-VAE tekniği kullanılır. VQ-VAE tekniğinde tahminler sayısal kodlarla ifade edilir. VQ-VAE tekniğinin kullanıldığı ön eğitim sürecine öğretmen modeli de denir. Öğretmen modeli, maskelenmiş yamaları öğrenerek bilgiyi öğrenci modeline aktarır. Modeldeki maskelenmiş kısımlara hangi kodların karşılık geleceği tahmin edilmeye çalışılır. Bu, bilgi damıtmanın kullanıldığı aşamadır. BeiT modeli iki aşamalı bir eğitim sürecine sahiptir. İlk aşamada model maskelenmiş görüntülerle eğitilir, maskelenmiş kısımlar öğrenilir ve maskelenmiş kısımların geri çağırılması öğrenilir. İkinci aşamada, daha önce öğrenilen bilgiler sınıflandırma görevinin titizlikle ayarlanması için kullanılır.


### 5.3.6. Deneysel Bulgular

Transformatör tabanlı DÖ modellerinin başarısı üzerinde damıtma belirteci kullanımının etkisini incelemek amacıyla Python programlama dili kullanılarak eğitim ve test ortamı hazırlanmıştır. Eğitim, doğrulama ve test süreçlerinde P100 GPU kullanılmıştır. AdamW optimizasyon algoritması ve  $5e-5$  öğrenme oranı tercih edilmiştir. 100 eğitim döngüsü (epoch) tekrarlanmış ve veri yığın boyutu (batch size) olarak 32 seçilmiştir. Tüm transformatör tabanlı DÖ modellerinde aynı parametreler kullanılmıştır. Çalışmalarda kullanılan hiper-parametreler aşağıda yer alan Tablo 10'da gösterilmektedir.


**Tablo 10.** Derin öğrenme modellerinde kullanılan hiper-parametreler

Hiper-parametreler	Değer
Veri yığın boyutu (Batch size)	32
Öğrenme oranı (Learning rate)	$5e-5$
Optimizasyon (Optimizer)	AdamW
Eğitim tur sayısı (Epoch)	100


DÖ modellerinde, modellerin başarısının ölçüldüğü önemli parametrelerden biri model kayıp grafikleridir. Sınıflandırma problemleri için kullanılacak en uygun fonksiyon CrossEntropyLoss grafiğini analiz etmektir. CrossEntropyLoss, model çıktıları ile doğru sınıf etiketleri arasındaki farkı ölçerek optimizasyon sürecini destekler. Optimizasyon sürecinde CrossEntropyLoss değerleri, modelin ağırlıklarını güncellemek için kullanılır. Çok sınıflı sınıflandırma problemlerinde, bir sınıfın doğru olasılıklarını maksimize ederken, diğer yanlış sınıfların olasılıklarını minimize etmeye odaklanır. Şekil 40'ta çalışmada kullanılan modellerin CrossEntropyLoss grafikleri gösterilmektedir.



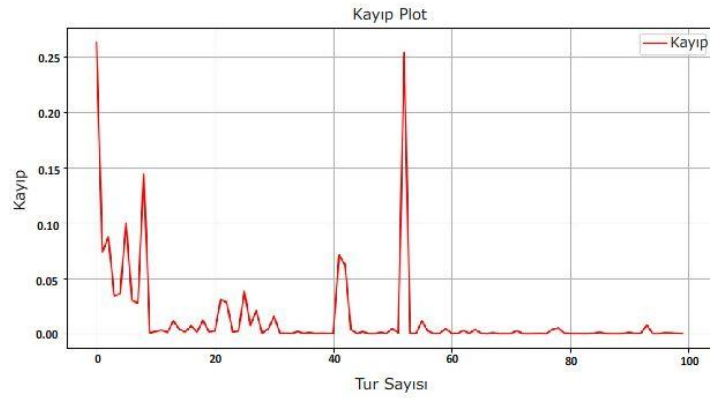
(a)



(b)



(c)



(d)

Şekil 40. Transformator tabanlı görüntü sınıflandırma modelleri çapraz entropi kayıp grafikleri (a) ViTx16 (b) ViTx32 (c) DeiT (d) BeiT

Derin öğrenme modellerinde, sınıflandırma başarısının en önemli gösterimlerinden biri karışıklık matrisidir. Karışıklık matrisi, bir sınıflandırma ölçüm birimi olmaktan ziyade, sınıflandırmada kullanılan değerlendirme metriklerinin hesaplanması için bir altyapı sağlar. Doğruluk, kesinlik ve F1 puanı gibi birçok değerlendirme metriği bu matris kullanılarak hesaplanır. Karışıklık matrisi iki sınıflı bir gösterime sahiptir ve bu çalışmada olduğu gibi çok sınıflı sınıflandırma problemlerinde de kullanılır. Tablo 11, damıtma belirteçleri olmayan transformatör modellerinden biri olan ViT modelinin sınıflandırma etiketlerini göstermektedir. Tabloda 0, 1, 2 ve 3 sınıfları sırasıyla glioma tümörü, menenjiyom tümörü, tümör yok ve hipofiz tümörünü temsil etmektedir.

**Tablo 11.** Transformatör tabanlı ancak bilgi tabanlı damıtma olmadan derin öğrenme modellerinden elde edilen test görüntüleri için sınıflandırma sonuçları

	Tahmini sınıf								
	ViTx32				ViTx16				
	0	1	2	3	0	1	2	3	
Gerçek sınıf	0	42	31	26	1	31	36	31	2
	1	0	112	3	0	0	114	1	0
	2	0	1	104	0	0	0	105	0
	3	0	6	6	62	0	1	10	63

Görüntü dönüştürücü modeli, derin öğrenmede dönüştürücülerin yeteneklerinden yararlanan ilk modeldir ve hiçbir damıtma belirteci kullanılmamıştır. Tablo 11’de elde edilen sınıflandırma sonuçları incelendiğinde, ViTx32 modelinde hasta olmayan bireylerin tamamen doğru bir şekilde tespit edildiği görülmektedir. Bilgi tabanlı damıtma yöntemini kullanan dönüştürücü tabanlı modellerin sınıflandırma sonuçları da Tablo 12’de verilmiştir. Bu aşamada, 4 modelin de aynı eğitim ve test verileri üzerinde çalıştırıldığına dikkat edilmelidir. Bu şekilde, veri kümelerinin rastgele dağılımından kaynaklanabilecek herhangi bir olası avantaj veya dezavantaj önlenmiştir.

**Tablo 12.** Bilgi tabanlı damıtma ile transformatör tabanlı derin öğrenme modellerinden elde edilen test görüntüleri için sınıflandırma sonuçları

	Tahmini sınıf								
	DeiT				BeiT				
	0	1	2	3	0	1	2	3	
Gerçek sınıf	0	46	32	21	1	34	42	19	5
	1	0	114	0	1	0	115	0	0
	2	0	0	105	0	0	0	105	0
	3	3	1	6	64	0	1	8	65

Bilgi damıtma belirteçlerinin kullanımının sınıflandırma başarısı üzerindeki etkisi simülasyonlarla gösterilmiştir. DeiT ve BeiT modelleri, menenjiyom tümörlerini ve tümör yok sınıflarını neredeyse hatasız bir şekilde tespit edebilmiştir. Sadece DeiT modeli, menenjiyom tümörü olarak etiketlenmesi gereken bir görüntüde hipofiz tümörü teşhis etmiştir, bu durum hariç, her iki modelin de iki sınıf için yaptığı tahminler tamamen doğrudur.

Çalışma, transformatör tabanlı modellerde bilgi tabanlı damıtma yöntemlerinin sınıflandırma performansına etkisini gözlemlemek için yürütülmüştür. Çalışma kapsamında, damıtmalı ve damıtmasız farklı DÖ modelleri eğitilmiş ve test sonuçları elde edilmiştir. Çalışmanın geri kalanında, modellerin üstünlüğünü daha detaylı incelemek amacıyla nicel analiz, zaman performansı analizi ve parametre verimliliği analizi yapılmış ve sonuçlar tablo halinde sunulmuştur.

### 5.3.6.1. Nicel Analiz

Derin öğrenme modellerinin performansını ölçülebilir parametrelerle göstermek, modelleri karşılaştırabilmek için önemlidir. Araştırmacılar, DÖ modellerinin daha başarılı veya başarısız olduğunu göstermek için doğruluk, kesinlik ve geri çağırma gibi birçok metrik kullanırlar. Bu metrikleri elde etmek için veri setinin test kısmı kullanılır. Test verileri üzerinde yapılan tahminler gerçek sınıflarla karşılaştırılır ve ardından belirli matematiksel formüllerle metrikler hesaplanır.

Çalışma kapsamında, damıtma teknikleri kullanılmadan iki farklı ViT modeli ve farklı damıtma teknikleri kullanılarak BeiT ve DeiT modelleri eğitilmiş ve elde edilen sonuçlar nicel değerlerle karşılaştırılmıştır. Sınıflandırma başarısı üzerinde damıtma tekniklerinin etkisini karşılaştırmak için eğitim ve test süreçleri için ViTx16, ViTx32, DeiT ve BeiT modelleri seçilmiştir. Bu çalışmada, damıtma tekniklerini kullanan ve transformatör tabanlı görüntüler üzerinde çalışan modellerin etkinliği gözlemlenmiştir. Tablo 13, transformatör tabanlı damıtma tekniklerini kullanan derin öğrenme yöntemleri ile transformatör tabanlı damıtma tekniklerini kullanmayan derin öğrenme yöntemlerinin karşılaştırmasını göstermektedir. Tabloda yer alan 0, 1, 2 ve 3 numaralı sınıflar sırasıyla glioma tümörü, menenjiyom tümörü, tümör yok ve hipofiz tümörü sınıflarını temsil etmektedir. Bilindiği üzere sağlık alanında sınıflandırma çalışmalarında hasta ve hasta olmayan bireyler arasında daha net çizgiler çizmek büyük önem taşımaktadır. Başka bir deyişle, DÖ tabanlı otonom bir hastalık teşhis uygulaması, hasta birey ile hasta olmayan bireyi net bir şekilde ayırt edebilmelidir.

Hasta olmayan bir bireye hastalık tanısı koymak, gelecekte yanlış tedaviye ve diğer istenmeyen sorunlara yol açabilir. Mevcut çalışma kapsamında, 2 numara ile etiketlenen tümörsüz sınıfın sınıflandırma sonuçlarını inceleyerek bu durumun performansına ulaşabiliriz. Hasta olmayan bireylerin doğruluk değerlendirme metriğinde, ViTx32, ViTx16, DeiT ve BeiT modellerinde sırasıyla %90.86, %89.34, %93.15 ve %93.15 sınıflandırma başarıları elde edilmiştir. Bu bağlamda, hasta olmayan bireylerde damıtma tekniklerinin kullanılmasının hastalık tanısı başarısında yaklaşık %3 artış sağladığı görülmüştür. Duyarlılık değerlendirme metriği açısından, damıtma teknikleriyle ViTx32 modeline kıyasla yaklaşık %5 ve ViTx16 modeline kıyasla yaklaşık %9'luk bir artış elde edildiği gözlemlenmiştir. 1 numara ile etiketlenen menenjiyom tümör sınıfı için sınıflandırma başarısında da bir artış söz konusudur. Damıtma tekniklerinin kullanımı menenjiyom tümör tespiti için yaklaşık %1.7'lik bir artış sağlamıştır. Aşağıda yer alan Tablo 13'te test görüntüleri üzerinde elde edilen tüm sınıflar için farklı değerlendirme metrikleriyle ayrı sınıflandırma sonuçları ve hesaplanan ağırlıklı ortalama doğruluk değerleri verilmiştir.

**Tablo 13.** Test görüntüleri üzerinde elde edilen tüm sınıflar için farklı değerlendirme metrikleriyle ayrı sınıflandırma sonuçları ve hesaplanan ağırlıklı ortalama doğruluk değeri

	0			1			2			3			Ağırlıklan dırılmış ortalama doğruluk
	Doğru luk	Kesin lik	Duy arlı lk	Doğru luk	Kesin Lik	Duy arlı lk	Doğru luk	Kesin lik	Duy arlı lk	Doğru luk	Kesin lik	Duy arlı lk	
ViTx 32	0.85	0.42	1.0	0.90	0.97	0.75	0.91	0.99	0.75	0.97	0.84	0.98	0.901
ViTx 16	0.82	0.31	1.0	0.90	0.99	0.75	0.89	1.0	0.71	0.97	0.85	0.97	0.892
DeiT	0.85	0.46	0.94	0.91	0.99	0.78	0.93	1.0	0.80	0.97	0.86	0.97	0.914
BeiT	0.83	0.34	1.0	0.90	1.0	0.73	0.93	1.0	0.80	0.96	0.88	0.93	0.900

*Ağırlıklandırılmış ortalama doğruluk (WAcc)*, DÖ ve MÖ algoritmalarında dengesiz veri kümelerini analiz etmek için sıklıkla kullanılan bir değerlendirme metriğidir. Bazı sınıfların çok sayıda görüntüye sahip olması ve bazı sınıfların daha az görüntüye sahip olması nedeniyle gerçekçi olmayan doğruluk hesaplamaları sorununu çözmek için WAcc kullanılması önerilir. WAcc, her sınıfın doğruluğunun o sınıfa ait örnek sayısına göre ağırlıklandırılmasıyla hesaplanır. 16x16 paket kullanan modeller arasındaki karşılaştırmada, damıtma belirteçlerinin kullanımının sınıflandırma başarısı üzerinde olumlu bir etkiye sahip olduğu gözlemlenmiştir. ViTx16 modeliyle karşılaştırıldığında, damıtma tekniğini kullanan BeiT modeli, yaklaşık %1 daha iyi sınıflandırma performansına sahiptir. Damıtma tekniğini kullanan bir diğer transformatör tabanlı model olan DeiT, ViTx16 modeliyle karşılaştırıldığında yaklaşık %2.2'lik bir sınıflandırma performansı artışına sahiptir.

### 5.3.6.2. Zaman Performans Analizi

Araştırmacıların çalışmalarında hangi DÖ modelini kullanacaklarına karar vermeleri için bir diğer önemli parametre ise eğitim süresidir. Transformatör tabanlı sistemlerin en önemli avantajlarından biri esnekliktir. Araştırmacılar, transformatör modelleri geliştirdikleri diğer sistemlere entegre ederek hayatı kolaylaştıracak birçok çözüm üretmektedir. Örneğin, transformatör tabanlı modeller görüntülerden özellik çıkarma aşamasında kodlayıcı olarak kullanılabilir ve ardından LSTM, GRU veya GPT gibi modellerle kod çözücü olarak tıbbi raporlar yazılabilir. Benzer şekilde, dönüştürücü modeller esnek yapıları nedeniyle özellik çıkarma, nesne tanıma veya segmentasyon gibi birçok alanda tercih edilmektedir. Eğitim süresi, özellikle sürekli eğitim gerektiren veya mobil cihazlarda çalıştırılacak projeler için önemli bir sorundur. Araştırmacılar bir model seçerken zaman verimliliği ve sınıflandırma başarısı parametrelerini birlikte göz önünde bulundurmalıdır. Bu bağlamda, damıtma tekniğiyle ve damıtma tekniği olmadan tüm modeller için aynı geliştirme ortamında gerçekleştirilen eğitimlerin zaman ortalamaları hesaplanmış ve Tablo 14'te sunulmuştur.

**Tablo 14.** Aynı geliştirme ortamında gerçekleştirilen eğitimlerin zaman ortalamaları

Model	Zaman (s)	Birim zaman kazancı %
ViTx32	6162	100%
ViTx16	6844	111%
DeiT	6602	107%
BeiT	6915	112%

Birim zaman kazancı parametresi, diğer modellerin en hızlı çalışan modele göre zaman verimliliğinin hesaplanmasıyla elde edilmiştir. Tablo 14'ten görülebileceği gibi, ViTx16 modeli ViTx32 modeline kıyasla %11 daha fazla çalışma süresine sahiptir. DeiT modeli ViTx32 modeline kıyasla %7 daha fazla çalışma süresine sahiptir. BeiT modeli ViTx32 modeline kıyasla %12 daha yüksek çalışma süresine sahiptir.

## 6. TARTIŞMA, SONUÇ ve ÖNERİLER

Çalışma kapsamında elde edilen veriler ışığında, beyin tümörlerinin tanı sürecine dair önemli bulgular elde edilmiştir. Bu bölümde, elde edilen bulguların analizi yapılarak sonuçlar tartışılmakta ve gelecekteki araştırmalar için önerilerde bulunmaktadır.

### 6.1. Tartışma

Çalışmamızın yöntemini seçerken odaklandığımız bir nokta, ESA tabanlı modellerin DSA modellerine kıyasla daha az parametre ile yüksek doğrulukta sınıflandırma yapması gerçeğiydi. Bu noktadan hareketle ESA mimarisini seçtik ve çalışma modelimizi oluştururken, model üzerinde farklı deneyler gerçekleştirerek çalışma süresini azaltmayı ve yüksek verimlilik elde etmeyi amaçladık. Literatürü incelediğimizde, ESA yaklaşımıyla yapılan bazı çalışmaların diğer birçok DSA yöntemlerinden daha yüksek performans gösterdiğini gördük. Bu çalışmada önerdiğimiz etkin ESA modelimiz de birçok DSA modeli geride bırakmış ve yüksek sınıflandırma doğruluğu göstermiştir.

Temel ESA modelimizde elde edilen %99.76 gibi oldukça yüksek doğruluk oranı, modelin sınıflandırma gücünün son derece etkili olduğunu göstermektedir. Bu sonuç, literatürdeki benzer çalışmalarda bildirilen doğruluk oranlarından daha yüksektir. Bu farkın temel nedeni, modelde kullanılan öznelik seçimi stratejilerinin başarısı, veri ön işleme adımlarının etkinliği ve alt uzaylarda çeşitlilik sağlayan topluluk öğrenme yaklaşımının gücüdür. Ayrıca, modelin aşırı öğrenmeden kaçınarak genellebilirliğini koruması da doğruluk oranını artıran önemli bir etmendir. Bu durum, önerdiğimiz ESA modelimizin özellikle karmaşık ve dengesiz veri setlerinde bile istikrarlı ve güvenilir sonuçlar verebileceğini ortaya koymaktadır.

Önerilen yeni ESA tabanlı modelimizin verimliliğini birçok yönden test ettik. Bu değerlendirmelerden biri modelin farklı bir veri seti ile eğitilmesiydi. Modelin performansının birden fazla veri setiyle ölçülmesinin daha doğru bir yaklaşım olacağını düşündük. Bunun için tümör tespit çalışmalarına girdi sunan Kaggle platformundan ücretsiz olarak temin ettiğimiz dört sınıflı veri seti-3 ile modelimizin performans metrik sonuçlarını değerlendirdik. Modelimizin iki farklı veri seti için sonuçlarını incelediğimizde, yüksek oranlarda sınıflandırma başarısına ulaştığını gözlemledik. Ulaşılan bu sonuçlar, modelimizin verimliliğini ve genelleştirme kabiliyetine sahip olduğunu kanıtlamaktadır.

Genel olarak tüm DÖ yaklaşımlarının hastalık tespiti ve sınıflandırması işlemini başarıyla gerçekleştirdiğinden bahsetmiştik. Bu derin yöntemler arasında performans oranları değişiklik göstermekte ve birbirlerine karşı üstün tarafları ve geride kalan yönleri bulunmaktadır. Modelimizi DSA'nın üstün yönleri ile karşılaştırdığımızda, sürekli sinyal üretme noktasında geride kalabilmektedir. Bu problemin üstesinden gelebilmek için ESA modelde boyut artırma yoluna gidilebilir. Ayrıca aşırı uyum gibi sorunlar, eğitimin daha erken bir aşamada durdurulması veya veri artırılması yoluyla önlenebilir. Çalışmamızda bu sorunu giderebilmek amacıyla eğitimi farklı aşamalarda durdurarak sonuçları gözlemledik. Bunun yanında bu yaklaşımın bir diğer dezavantajı, küçük veri setlerinde bile eğitim süresinin uzun sürebilmesidir. Bu dezavantajların dışında, modelimizin katman sayısının ve parametrelerin değiştirilebilir olması modelin en büyük avantajlarından biridir. Bu sayede ESA model, tümör tespiti ve sınıflandırması için en uygun yapıya kavuşabilmektedir. Biz de sıfırdan oluşturduğumuz ESA modelimizde birçok farklı yöntemi denedikten sonra en uygun sonuçlar ışığında modelimize son şeklini verdik.

Bu tez çalışmasında odaklandığımız bir diğer nokta, beyin tümörlerinin sınıflandırılmasına yönelik olarak transformatör tabanlı modellerde bilgi tabanlı damıtma yöntemlerinin sınıflandırma performansına etkisini ayrıntılı bir şekilde incelemektir. Karmaşık beyin tümörü görüntülerinin işlenmesinde, transformatörlerin güçlü temsil öğrenme kapasitesi, bilgi tabanlı damıtma ile desteklendiğinde, modelin doğruluğunu ve kararlılığını belirgin şekilde artırdığı görülmüştür. Çalışmada karşılaştırılan geleneksel transfer öğrenme yöntemleri ve damıtma destekli modeller arasında, damıtma yönteminin öğrenci modele sağladığı daha iyi kavramsal genelleme yeteneği dikkat çekmiştir. Ayrıca, bilgi tabanlı damıtma yöntemlerinin farklı damıtma stratejileri ile uygulanmasının, model performansı üzerindeki etkileri de değerlendirilmiştir. Beyin tümörü sınıflandırmasında hem doğruluk oranlarında hem de modelin belirsizlik karşısındaki dayanıklılığında kayda değer iyileşmeler elde edilmiştir. Bu bulgular, bilgi tabanlı damıtma yöntemlerinin transformatör modelleriyle entegrasyonunun, tıp alanındaki tanı sistemleri için umut verici bir yaklaşım sunduğunu ortaya koymaktadır.

Bu çalışmada kullanılan ViTx16 ve ViTx32 gibi damıtma tekniği kullanılmayan modellerle, DeiT ve BeiT gibi damıtma tekniğini entegre eden modellerin karşılaştırması yapılmıştır. Elde edilen sonuçlar, damıtma belirteci kullanan DeiT ve BeiT modellerinin, özellikle az sayıda veriyle çalışıldığında sınıflandırma başarısını önemli ölçüde artırdığını göstermektedir. Özellikle DeiT modelinin ViTx16 modeline kıyasla %2.2'lik bir başarı artışı sağlaması, damıtma tekniklerinin etkisini açıkça ortaya koymaktadır. Ayrıca, hasta olmayan bireylerin tespitinde damıtma yönteminin %4'e varan bir performans artışı sağladığı gözlemlenmiştir.

Çalışmada ayrıca modellerin eğitim süreleri de karşılaştırılmış ve damıtma tekniklerinin getirdiği ek yük detaylı şekilde analiz edilmiştir. ViTx32 modeli en hızlı eğitim süresine sahipken, DeiT modeli bu süreye %7'lik bir ek yük getirmiştir. BeiT modelinde ise bu artış %12 seviyesine ulaşmıştır. Bu durum, damıtma yöntemlerinin sağladığı doğruluk artışına rağmen, eğitim süresindeki bu ek maliyetin uygulama alanlarına göre dikkatlice değerlendirilmesi gerektiğini göstermektedir. Ayrıca sonuçlar, damıtma tekniklerini kullanan modellerin hasta olmayan bireylerin doğru teşhisinde sağladığı başarıyı vurgulamaktadır. Özellikle DeiT ve BeiT modelleri, ViTx16 ve ViTx32'ye kıyasla bu sınıfta yaklaşık %3-4 oranında daha yüksek doğruluk sergilemiştir. Bu başarı, tıbbi görüntüleme alanında erken teşhis ve doğru tanının kritik olduğu durumlarda damıtma destekli modellerin ne denli etkili olabileceğini ortaya koymaktadır.

## 6.2. Sonuç ve Öneriler

Bu tez çalışması, derin öğrenme tabanlı yöntemler kullanılarak üç farklı uygulama ile gerçekleştirilmiştir. İlk uygulamada transfer öğrenme modeline sahip bir ESA, VGG-16 ağı kullanılarak beyin tümörünün tespit edilmesi yoluyla sınıflandırılması (tümör var, tümör yok) amaçlanmıştır. Burada girdi MR görüntüleri, Kaggle platformundan alınmış ve gürültüleri gidermek, görüntü kalitesini artırmak için ön işlem adımlarına tabi tutulmuştur. Daha sonra özellik çıkarımı yapılmış ve tümörün tespit ve sınıflandırılması adımları gerçekleştirilmiştir. Bununla birlikte bu araştırma, ESA model sınıflandırma probleminin (deneğin beyin tümörü olup olmadığını tahmin etmek için) ve Bilgisayarla Görme probleminin (MRG taramalarından beyin kırpması sürecini otomatikleştirmek için) bir kombinasyonudur. Nihai doğruluk, %50 taban çizgisinden çok daha yüksektir. Ancak, veri setimizin az sayıda görüntü içermesi bu çalışmanın bir sınırlılığıdır. Daha fazla sayıda girdi görüntüsü kullanılmasıyla veya model hiper-parametrelerinin ayarlanması yoluyla performans ölçüt değerleri artırılabilir.

Bir diğerk deneysel uygulamamızda, verimli yeni bir evriřimli sinir ağı tabanlı model kullanılarak beyin tümörü görüntülerinin çoklu sınıflandırmasına ilişkin sıfırdan yeni bir model geliştirilmiştir. Bu uygulama, MR görüntülerinden beyin tümörlerini otomatik sınıflandıran ESA tabanlı bir derin öğrenme modeli sunmuştur. Çalışmada kullanılan beyin MR görüntüleri, arařtırmacılara girdi sunan Kaggle platformundan alınmıştır. Önerilen model beyin görüntülerinin ön işleme adımlarıyla başlamaktadır. Çalışmada kullanılan görüntüler bazı ön işlemlerden geçirilerek gürültüler giderilmiş ve görüntü kalitesi artırılmıştır. Ayrıca görüntüden öznelikler çıkarılmış ve evriřim ağı ile uygulanmıştır. Modelimizin ilk doğruluk çıktısını yüksek oranda elde etmiş olsak da daha iyi bir performans doğruluğu için farklı parametre değerleri kullanarak %99.76 nihai doğruluk elde ettik. Önemli bir aşama olarak, fazla uydurmanın önüne geçmek için modelimizde tam bağlantılı katmanın sonuna bir seyreltme katmanı ekledik. Modelimizin verimliliğini doğrulamak için çalışmamızı, halka açık veri seti sunan Kaggle web platformunda beyin tümörü MR görüntüleri ile uygulanmış başarılı çalışmalarla karşılařtırdık. Bununla birlikte, kabul gören önemli dergilerde yayınlanan makalelerin deneysel sonuçları ile önerdiğimiz modelin performansını karşılařtırmalı olarak sunduk. Önerdiğimiz etkin yeni ESA tabanlı sinir ağı modelimiz tümör türlerini ve tümör olmayan görüntülerin sınıflandırılmasını önemli ölçüde iyileştirmiştir. Bunun yanında deneysel sonuçlar, önerdiğimiz modelin doğruluk, kesinlik F1 puanı gibi değerlendirme kriterleri açısından da birçok transfer öğrenme metodundan daha iyi performans gösterdiğini ortaya koymuştur.

Tez çalışmamızın özgünlüğünü artıran bir diğerk uygulama çalışmamız daha önce literatürde denenmemiş bir çalışmaydı. Bu çalışmanın temel amacı, veri sayısı az olan veri kümelerinde, damıtma tekniklerinin transformatör tabanlı modellerin performansına etkisini arařtırmaktır. Çalışmamızda, transformatör tabanlı olup damıtma tekniklerini kullanmayan ViTX32 ve ViTX16 modelleriyle, damıtma tekniklerini kullanan DeiT ve BeiT modelleri ile eğitim ve test süreçlerinde beyin MR görüntülerini içeren dört sınıflı veri seti kullanılmıştır. Benzer parametreler ve aynı geliştirme ortamı kullanılarak gerçekleştirilen eğitim ve test süreçleriyle elde edilen sonuçlar detaylı olarak analiz edilmiştir.

Çalışmada, damıtma belirteci kullanımı ağırlıklı ortalamalarla dikkate alındığında, ViTx16 modelinin, damıtma tekniğı kullanan BeiT modeline göre yaklaşık %1 daha başarılı bir sınıflandırma performansına sahip olduğı görülmüştür. Damıtma tekniğı kullanan bir diğerk transformatör tabanlı model olan DeiT modeli ise ViTx16 modeline kıyasla sınıflandırma başarısında yaklaşık %2.2'lik bir artış sağlamıştır. Sınıflandırma sonuçlarına daha detaylı bakıldığında, hasta olmayan bireylerin tespitinde damıtma tekniğinin kullanılmasının sınıflandırma performansını yaklaşık %4 oranında artırdığı gözlemlenmiştir. Sınıflandırma performansının yanı sıra modeller zaman performansı açısından da analiz edilmiştir. Damıtma belirteçleri kullanan modeller ViTx16 modeliyle karşılařtırıldığında, DeiT modelinin daha kısa sürede çalıştığı, BeiT modelinin ise yalnızca %1 daha fazla zaman tükettiğı gözlemlenmiştir.

Bu çalışmanın literatüre katkısı, transformatör tabanlı derin öğrenme modellerinde bilgi tabanlı damıtma tekniklerinin sınıflandırma performansına olan etkisini kapsamlı bir şekilde ortaya koymasıdır. Özellikle tıbbi görüntüleme alanında, az sayıda veriyle çalışıldığında bile yüksek doğruluk oranlarına ulaşılabileceğini göstererek, sınırlı veri setleriyle çalışan arařtırmacılar için önemli bir referans oluşturmaktadır. DeiT ve BeiT modellerinin ViTx tabanlı modellere kıyasla sağladığı performans artışı, bu alandaki mevcut çalışmaların ötesine geçerek, damıtma yöntemlerinin potansiyelini somut verilerle desteklemektedir. Ayrıca, çalışmanın sunduğı detaylı zaman ve

performans analizleri, model seçiminde doğruluk ve işlem süresi arasındaki dengenin nasıl sağlanabileceğine dair önemli çıkarımlar sunmaktadır. Eğitim süresindeki artışa rağmen, elde edilen yüksek sınıflandırma başarısı, özellikle tıbbi tanı gibi kritik alanlarda damıtma tekniklerinin ne denli etkili olabileceğini göstermektedir. Bu yönüyle çalışma, hem teorik katkı sağlamakta hem de pratik uygulamalara ışık tutmaktadır.

Küçük veri kümeleri üzerinde yaptığımız bu çalışma, özellikle salgın hastalıklar veya büyük veri kümeleri oluşturmanın zor olduğu diğer hastalıklar gibi özel durumlarda tıp alanında çalışanlara rehberlik edecektir. Çalışmamız, sınırlı verilerle çalışırken damıtma tekniklerinin önemli sınıflandırma başarısı sağlayabileceğini göstermiştir. Çalışmamızın sınırlılıkları, transformatör tabanlı modellerde girdi olarak görüntülerin uygulanması ve veri kümesinin beyin MR görüntüleri içermesidir. Gelecekteki çalışmalarda, hibrit damıtma teknikleri incelenebilir ve damıtma tekniklerinin nasıl iyileştirilebileceği araştırılabilir.

Gelecek çalışma önerilerine ek olarak, makalede sunulan ESA tabanlı modelin daha karmaşık ve derin mimarilerle genişletilmesine odaklanılabilir. Özellikle farklı transfer öğrenme yaklaşımları ve hibrit modellerle ESA'nın entegrasyonu, sınıflandırma performansını daha da artırabilir. Ayrıca, çeşitli veri artırma teknikleri ve sentetik veri üretimiyle modelin az veriyle çalışırken gösterdiği başarının optimize edilmesi mümkündür. Çok modluluk (Multi-modality) yaklaşımıyla MR görüntülerinin yanı sıra farklı tıbbi görüntüleme tekniklerinin birleştirilmesi, modelin tanı kabiliyetini güçlendirebilir. Bunun yanında, model eğitimi sırasında kullanılan parametrelerin değiştirilmesiyle farklı eğitim süreçleri kurgulanabilir. Son olarak, *Açıklanabilir YZ (Explainable AI)* yöntemlerinin entegre edilmesiyle modelin karar mekanizmalarının şeffaflığı artırılarak klinik pratikte güvenilirliği desteklenebilir.

## KAYNAKLAR

- Abe, E., Suzuki, M., Ichimura, K., Arakawa, A., Satomi, K., Ogino, I., ... & Kondo, A. (2024). Implications of DNA Methylation Classification in Diagnosing Ependymoma. *World Neurosurgery*, 185, e1019-e1029.
- Abiwinanda, N., Hanif, M., Hesaputra, S. T., Handayani, A. & Mengko, T. R. (2019). Brain tumor classification using convolutional neural network. In *World Congress on Medical Physics and Biomedical Engineering 2018: June 3-8, 2018, Prague, Czech Republic (Vol. 1)* (pp. 183-189). Springer Singapore.
- Aden, D., Zaheer, S., Kumar, R. & Ranga, S. (2023). Monkeypox (Mpox) outbreak during COVID-19 pandemic—Past and the future. *Journal of Medical Virology*, 95(4). Doi:10.1002/jmv.28701
- Akkuzu, N., Ucan, M. & Kaya, M. (2023, October). Classification of multi-label electrocardiograms utilizing the EfficientNet CNN model. In *2023 4th International Conference on Data Analytics for Business and Industry (ICDABI)* (pp. 268–272). IEEE. Doi:10.1109/ICDABI60145.2023.10629383
- Akyel, A & Akdemir Özışık P. (2020). Artificial intelligence applications in brain tumors. Hardalaç F, Serhatlioglu S, editors. *Artificial Intelligence Techniques and Application in Radiology*. 1st Edition. Ankara: Türkiye Clinics. p.17-22.
- Algren, M., Fisher, W. & Landis, A. E. (2021). Machine learning in life cycle assessment. In *Data Science Applied to Sustainability Analysis* (pp. 167-190). Elsevier. Doi:10.1016/B978-0-12-817976-5.00009-7
- Alotaibi, A., et al. (2023, January). ViT-DeiT: An ensemble model for breast cancer histopathological images classification. In *2023 1st International Conference on Advanced Innovations in Smart Cities (ICAISC)* (pp. 1–6). IEEE. Doi:10.1109/ICAISC56366.2023.10085467
- Alzahrani, S. M. & Qahtani, A. M. (2024). Knowledge distillation in transformers with tripartite attention: Multiclass brain tumor detection in highly augmented MRIs. *Journal of King Saud University-Computer and Information Sciences*, 36(1), 101907.
- Amin, M., Nahar, K. M., Gharaibeh, H., Nasayreh, A., Alomar, A., Malkawi, M., ... & Abualigah, L. (2025). DieT Transformer model with PCA-ADE integration for advanced multi-class brain tumor classification. *Intelligence-Based Medicine*, 11, 100192.
- Arnab, A., Deghani, M., Heigold, G., Sun, C., Lučić, M. & Schmid, C. (2021). Vivit: A video vision transformer. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 6836-6846).
- Aslan, E. (2024). LSTM-ESA Hibrit Modeli ile MR Görüntülerinden Beyin Tümörünün Sınıflandırılması. *Adiyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 11(22), 63-81.
- Aslan, E., Arserim, M. A. & Uçar, A. (2023). Development of Push-Recovery control system for humanoid robots using deep reinforcement learning. *Ain Shams Engineering Journal*, 14(10), 102167. Doi: 10.1016/j.asej.2023.102167.
- Aslan, M. (2022). Deep Learning Based Automatic Brain Tumor Detection. *Firat University Journal of Engineering Sciences*, 34(1), 399-407. Doi:10.35234/fumbd.1039825
- Ayadi, W., Elhamzi, W., Charfi, I. & Atri, M. (2021). Deep CNN for brain tumor classification. *Neural processing letters*, 53, 671-700. Doi: 10.1007/s11063-020-10398-2
- Badža, M. M. & Barjaktarović, M. Č. (2020). Classification of brain tumors from MRI images using a convolutional neural network. *Applied Sciences*, 10(6), 1999. Doi:10.3390/app10061999
- Bali, M. (2020). *Renal Hücre Karsinomunda Aday Tümör Baskılayıcı Bnc1, Scube3, Sfrp1 ve Pcdh8 Genlerinin Epigenetik Analizi*. Yüksek Lisans Tezi, Bezmialem Vakıf Üniversitesi Sağlık Bilimleri Enstitüsü, İstanbul.
- Bao, H., Dong, L., Piao, S. & Wei, F. (2021). BEiT: BERT pre-training of image transformers. *arXiv preprint arXiv:2106.08254*. Doi: 10.48550/arXiv.2106.08254
- Barulina, M., Sanbaev, A., Okunkov, S., Ulitin, I. & Okoneshnikov, I. (2022). Deep learning approaches to automatic chronic venous disease classification. *Mathematics*, 10(19), 3571. Doi: 10.3390/math10193571

- Bauer, S., Wiest, R., Nolte, L. P. & Reyes, M. (2013). A survey of MRI-based medical image analysis for brain tumor studies. *Physics in Medicine & Biology*, 58(13), R97.
- Bell, E. H., Zhang, P., Shaw, E. G., Buckner, J. C., Barger, G. R., Bullard, D. E., ... & Chakravarti, A. (2020). Comprehensive genomic analysis in NRG oncology/RTOG 9802: a phase III trial of radiation versus radiation plus procarbazine, lomustine (CCNU), and vincristine in high-risk low-grade glioma. *Journal of Clinical Oncology*, 38(29), 3407-3417.
- Berger, T. R., Wen, P. Y., Lang-Orsini, M. & Chukwueke, U. N. (2022). World Health Organization 2021 classification of central nervous system tumors and implications for therapy for adult-type gliomas: a review. *JAMA oncology*, 8(10), 1493-1501.
- Bhanothu, Y., Kamalakannan, A. & Rajamanickam, G. (2020, March). Detection and classification of brain tumor in MRI images using deep convolutional network. In *2020 6th international conference on advanced computing and communication systems (ICACCS)* (pp. 248-252). IEEE.
- Bradley, W. G. (1993). MR appearance of intracranial hemorrhage. *Radiology*, 189(1), 15-26. Doi: 10.1148/radiology.189.1.8372185.
- Chan, K. H., et al. (2004). Detection of SARS coronavirus in patients with suspected SARS. *Emerging Infectious Diseases*, 10(2), 294-299. Doi: 10.3201/eid1002.030610
- Çinar, A. & Yildirim, M. (2020). Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture. *Medical hypotheses*, 139, 109684. Doi:10.1016/j.mehy.2020.109684
- DeAngelis, L. M. (2001). Brain tumors. *New England Journal of Medicine*, 344(2), 114-123. Doi: 10.1056/NEJM200101113440207
- Deepak, S. & Ameer, P. M. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in biology and medicine*, 111, 103345. Doi: 10.1016/j.combiomed.2019.103345
- Deepak, S. & Ameer, P. M. (2021). Automated categorization of brain tumor from mri using cnn features and svm. *Journal of Ambient Intelligence and Humanized Computing*, 12, 8357-8369. Doi: 10.1007/s12652-020-02568-w
- Doğan, F. & Türkoğlu, İ. (2019). A compilation of deep learning models and application areas. Dicle University Engineering Faculty Journal of Engineering, 10(2), 409-445.
- Dosovitskiy, A. et al. (2020). "An image is worth 16x16 words: Transformers for image recognition at scale." *arXiv preprint arXiv:2010.11929*.
- Edgar, T. & Manz, D. (2017). *Research methods for cyber security*. Syngress.
- Ellis, H. L. & Teo, J. T. (2024). The influence of AI in medicine. *Medicine*, 52(12): 811-815. Doi: 10.1016/j.mpmed.2024.09.006
- Ferdous, G. J., Sathi, K. A., Hossain, M. A., Hoque, M. M. & Dewan, M. A. A. (2023). LCDEiT: A linear complexity data-efficient image transformer for MRI brain tumor classification. *IEEE Access*, 11, 20337-20350. Doi: 10.1109/ACCESS.2023.3244228
- Ganatra, N. & Patel, A. (2018). A comprehensive study of deep learning architectures, applications and tools. *Int. j. comput. sci. eng*, 6(12), 701-705.
- Geçmez, A. & Gençer, Ç. (2021). "Wind Energy Production Estimation with ANN and ANFIS". *9th International Conference on Smart Grid (icSmartGrid)*, Setubal, Portugal. pp. 167-173. Doi: 10.1109/icSmartGrid52357.2021.9551254.
- Goceri, E. (2025). An efficient network with CNN and transformer blocks for glioma grading and brain tumor classification from MRIs. *Expert Systems with Applications*, 268, 126290. Doi: 10.1016/j.eswa.2024.126290
- Gou, J., Yu, B., Maybank, S. J. & Tao, D. (2021). Knowledge distillation: A survey. *International Journal of Computer Vision*, 129(6), 1789-1819. Doi: 10.1007/s11263-021-01453-z
- Hinton, G., Vinyals, O. & Dean, J. (2015, March). Distilling the knowledge in a neural network. *arXiv*. Retrieved from <http://arxiv.org/abs/1503.02531>
- Houssein, E. H., Emam, M. M. & Ali, A. A. (2022). An optimized deep learning architecture for breast cancer diagnosis based on improved marine predators algorithm. *Neural Computing and Applications*, 34(20), 18015-18033. Doi:10.1007/s00521-022-07445-5

- Ibrahem, H., Salem, A. & Kang, H.-S. (2022). RT-ViT: Real-time monocular depth estimation using lightweight vision transformers. *Sensors*, 22(10), 3849. Doi: 10.3390/s22103849
- Jain, B. S. U. & Menon, P. G. (2023). Classification of abnormal cardiac rhythm from brief single-lead ECG recordings using embeddings from transformer encoder models. In *2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)* (pp. 4899–4901). IEEE. Doi: 10.1109/BIBM58861.2023.10385454
- Jalalifar S. A. & Sadeghi-Naini, A. (2022). “Data-Efficient Training of Pure Vision Transformers for the Task of Chest X-ray Abnormality Detection Using Knowledge Distillation,” in *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, IEEE, pp. 1444–1447. Doi: 10.1109/EMBC48229.2022.9871372.
- Jia, L., Zhong, H., Wang, X., Huang, L. & Lu, X. (2021). The symptoms, causes, and repairs of bugs inside a deep learning library. *Journal of Systems and Software*, 177, 110935.
- Johnson, D. R., Guerin, J. B., Giannini, C., Morris, J. M., Eckel, L. J. & Kaufmann, T. J. (2017). 2016 updates to the WHO brain tumor classification system: what the radiologist needs to know. *Radiographics*, 37(7), 2164-2180.
- Karabulut, M. E. (2016). Biyomedikal Veri Sınıflandırmasında Derin Öğrenme Yaklaşımlarının Araştırılması. Doktora Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.
- Kaur, H. & Gill, A. K. (2017). Review of Brain Tumor Detection Using Various Techniques. *Int. J. Adv. Res. Comput. Sci. Softw. Eng.*, 7(5), 867-870.
- Kucukkulahli, E. & Kabakus, A. T. (2024). Towards understanding cat vocalizations: A novel cat sound classification model based on vision transformers. *Applied Acoustics*, 226, 110218. Doi: 10.1016/j.apacoust.2024.110218
- Kumar, K. A., Prasad, A. Y. & Metan, J. (2022). A hybrid deep CNN-Cov-19-Res-Net Transfer learning architype for an enhanced Brain tumor Detection and Classification scheme in medical image processing. *Biomedical Signal Processing and Control*, 76, 103631. Doi: 10.1016/j.bspc.2022.103631
- Kumar, R. L., Kakarla, J., Isunuri, B. V. & Singh, M. (2021). Multi-class brain tumor classification using residual network and global average pooling. *Multimedia Tools and Applications*, 80, 13429-13438. Doi: 10.1007/s11042-020-10335-4
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., ... & Guo, B. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 10012-10022).
- Louis, D. N, Ohgaki, H., Wiestler, O.D., Ellison, D.W., Figarella-Branger, D., Perry, A., et al. (2016) *WHO classification of tumours of the central nervous system* (revised 4th ed.). IARC: Lyon, 2016.
- Louis, D.N., Ohgaki, H., Wiestler, O.D. et al. (2007). The 2007 WHO classification of tumours of the central nervous system. *Acta Neuropathol*, 114(2):97-109.
- Louis, D.N., Perry, A., Reifenberger, G., Von Deimling, A., Figarella-Branger, D., Cavenee, W.K., Ohgaki, H., Wiestler, O.D., Kleihues, P., Ellison, D.W. (2016). The 2016 World Health Organization Classification of Tumors of the Central Nervous System: A summary. *Acta Neuropathol*, 131, 803–820. [CrossRef] [PubMed] Doi: 10.1007/s00401-016-1545-1
- Luo, M., Guo, L., Yu, M., Jiang, W. & Wang, H. (2020). The psychological and mental impact of coronavirus disease 2019 (COVID-19) on medical staff and general public – A systematic review and meta-analysis. *Psychiatry Research*, 291, 113190. Doi: 10.1016/j.psychres.2020.113190
- Marchevsky, A. M. (2007). The use of artificial neural networks for the diagnosis and estimation of prognosis in cancer patients. In *Outcome prediction in cancer* (pp. 243-259). Elsevier.
- Maurício, J., Domingues, I. and Bernardino, J. (2023). “Comparing Vision Transformers and Convolutional Neural Networks for Image Classification: A Literature Review,” *Applied Sciences*, 13(9), p. 5521, Apr. 2023. Doi: 10.3390/app13095521.
- Merhemic, Z., Stosic-Opincal, T. & Thurnher, M. M. (2016). Neuroimaging of spinal tumors. *Magnetic Resonance Imaging Clinics*, 24(3), 563-579.

- Miller, K. D., Ostrom, Q. T., Kruchko, C., Patil, N., Tihan, T., Cioffi, G., ... & Barnholtz-Sloan, J. S. (2021). Brain and other central nervous system tumor statistics, 2021. *CA: a cancer journal for clinicians*, 71(5), 381-406. Doi: 10.3322/caac.21693.
- Mudda, M., Manjunath, R. & Krishnamurthy, N. (2020). Brain Tumor Classification Using Enhanced Statistical Texture Features. *IETE Journal of Research*, 1-12.
- Nazir, M. I., Akter, A., Wadud, M. A. H. & Uddin, M. A. (2024). Utilizing customized CNN for brain tumor prediction with explainable AI. *Heliyon*, 10(20), e38997. Doi: 10.1016/j.heliyon.2024.e38997
- Nhut, D. T. N., Tan, T. D., Quoc, T. N. & Hoang, V. T. (2024). Medicinal plant recognition based on Vision Transformer and BEiT. *Procedia Computer Science*, 234, 188–195. Doi: 10.1016/j.procs.2024.02.165.
- Önal, M. (2023). Beyin BT Görüntülerinden İnme Teşhisine Yönelik Derin Öğrenme Tabanlı Hekim Karar Destek Sistemi. Fırat Üniversitesi Fen Bilimleri Enstitüsü Ekobilisim Anabilim Dalı, Yüksek Lisans Tezi, Elazığ.
- Patil, S. & Kirange, D. (2023). Community of Deep Learning Models for Brain Tumor Detection. *Procedia Computer Science*, 218, 2468-2479.
- Pérez-García, F., Sparks, R. & Ourselin, S. (2021). TorchIO: a Python library for efficient loading, preprocessing, augmentation and patch-based sampling of medical images in deep learning. *Computer Methods and Programs in Biomedicine*, 106236.
- Rabby, S. F., Arafat, M. A. & Hasan, T. (2024). BT-Net: An end-to-end multi-task architecture for brain tumor classification, segmentation, and localization from MRI images. *Array*, 22, 100346.
- Rai, H. M. & Chatterjee, K. (2020). Detection of brain abnormality by a novel Lu-Net deep neural CNN model from MR images. *Machine Learning with Applications*, 2, 100004.
- Rajesh, N., Yalavarthy, A. B., Vamsi, V. K. & Saranya, G. (2024). BEiT transformer models to aid in the early detection of Parkinson illness. In *2024 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI)* (pp. 1–7). IEEE. Doi: 10.1109/ACCAI61061.2024.10602201.
- Serhatloğlu, S. & Hardalaç, F. (2009). Artificial Intelligence Techniques and Application to Radiology. *Firat Medical Journal*, 14(1): 01-06.
- Shin, H., Jeon, S., Seol, Y., Kim, S. & Kang, D. (2023). Vision transformer approach for classification of Alzheimer's disease using 18F-Florbetaben brain images. *Applied Sciences*, 13(6), 3453. Doi:10.3390/app13063453
- Singh, S., Kumar, M., Kumar, A., Verma, B. K., Abhishek, K. & Selvarajan, S. (2024). Efficient pneumonia detection using vision transformers on chest X-rays. *Scientific Reports*, 14(1), 2487. Doi:10.1038/s41598-024-52703-2
- Sprincl L, Vozenilek J, Vedralová J, Zicha D, Marík V, Zdráhal Z, et al. (1985). Use of a computer program in the diagnosis of brain tumors. *Cesk Patol*, 21(4):218-22.
- Sultan, H. H., Salem, N. M. & Al-Atabany, W. (2019). Multi-classification of brain tumor images using deep neural network. *IEEE access*, 7, 69215-69225. Doi: 10.1109/ACCESS.2019.2919122
- Suwala, A. K., Felix, M., Friedel, D., Stichel, D., Schrimpf, D., Hinz, F., ... & Reuss, D. E. (2022). Oligosarcomas, IDH-mutant are distinct and aggressive. *Acta neuropathologica*, 143(2), 263-281.
- Swapnil, S. A. & Girish, V. S. (2020, March). Image Mining Methodology for Detection of Brain Tumor: A Review. In *2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC)* (pp. 232-237). IEEE.
- Şahin, E., Özdemir, D. & Temurtaş, H. (2024). Multi-objective optimization of ViT architecture for efficient brain tumor classification. *Biomedical Signal Processing and Control*, 91, 105938.
- Tandel, G. S., Biswas, M., Kakde, O. G., Tiwari, A., Suri, H. S., Turk, M., ... & Suri, J. S. (2019). A review on a deep learning perspective in brain cancer classification. *Cancers*, 11(1), 111.
- Tee, M. L., et al. (2020). Psychological impact of COVID-19 pandemic in the Philippines. *Journal of Affective Disorders*, 277, 379–391. Doi: 10.1016/j.jad.2020.08.043
- Thust, S. C., Heiland, S., Falini, A., Jäger, H. R., Waldman, A. D., Sundgren, P. C. & Stupp, R. (2018). Glioma imaging in adults. *Neuroradiology*, 60, 229-245. Doi: 10.1007/s00234-018-2001-3

- Toğaçar, M. & Ergen, B. (2019). Biyomedikal görüntülerde derin öğrenme ile mevcut yöntemlerin kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1), 109-121.
- Tom, M. C., Milano, M. T., Chao, S. T., Soltys, S. G., Knisely, J. P., Sahgal, A., ... & Chang, E. L. (2022). Executive summary of American Radium Society's appropriate use criteria for the postoperative management of lower grade gliomas. *Radiotherapy and Oncology*, 170, 79-88.
- Touvron, H., Cord, M., Douze, M., Massa, F., Sablayrolles, A. and Jégou, H. (2021). "Training data-efficient image transformers & distillation through attention," in *International conference on machine learning*, PMLR, pp. 10347–10357. Doi: 10.1109/ACCESS.2023.3244228.
- Tummala, S., Kadry, S., Bukhari, S. A. C. & Rauf, H. T. (2022). Classification of brain tumor from magnetic resonance imaging using vision transformers ensembling. *Current Oncology*, 29(10), 7498-7511.
- Vankdothu, R., Hameed, MA. & Fatima, H. (2022). A Brain Tumor Identification and Classification Using Deep Learning based on CNN-LSTM Method. *Computers and Electrical Engineering*, 101, 107960. Doi:10.1016/j.compeleceng.2022.107960
- Willis, J., Smith, C., Ironside, J.W., Erridge, S., Whittle, I.R., Everington, D. (2005). The accuracy of meningioma grading: a 10-year retrospective audit. *Neuropathol Appl Neurobiol*, 31(2):141-149.
- Wirsching, H. G. & Weller, M. (2017). Glioblastoma. *Malignant Brain Tumors: State-of-the-Art Treatment*, 265-288.
- Xin, C., Li, Y., Zhang, F., Wang, H., Zhou, J. & Liu, Q. (2022). An improved transformer network for skin cancer classification. *Computers in Biology and Medicine*, 149, 105939. Doi:10.1016/j.compbimed.2022.105939
- Yin, Y., Jin, W., Bai, J., Liu, R. & Zhen, H. (2022). SMIL-DeiT: Multiple instance learning and self-supervised vision transformer network for early Alzheimer's disease classification. In *2022 International Joint Conference on Neural Networks (IJCNN)*. (pp. 1–6). IEEE. Doi: 10.1109/IJCNN55064.2022.9892524.
- Zhang, Q. & Yang, Y. B. (2021). Rest: An efficient transformer for visual recognition. *Advances in neural information processing systems*, 34, 15475-15485.
- URL-1 Brain tumor. (2019, April 27). Erişim Tarihi:28.12.2024. İnternet Adresi: <https://www.mayoclinic.org/diseases-conditions/brain-tumor/symptoms-causes/syc-20350084>.
- URL-2 Charles Patrick Davis, MD. (2023). "Cancer Causes, Types, Treatment, Symptoms & Signs." MedicineNet. Erişim Tarihi: 27.12.2024. İnternet Adresi: <https://www.medicinenet.com/cancer/article.htm>.
- URL-3 Dere, Ü. A. (2017). What is a brain tumor? Erişim Tarihi:09.05.2022. İnternet Adresi:<https://ankara.baskenthastaneleri.com/magazine/sayi30/files/assets/common/downloads/publication.pdf>
- URL-4 Brain and Nerve Surgery (Neurosurgery) (2023). What are brain tumor symptoms? What are the treatment methods? Erişim Tarihi:25.07.2023. İnternet Adresi: <https://www.medicalpark.com.tr/beyin-tumorleri/hg-1539>
- URL-5 Acıbadem Web and Editorial Board (2019). Erişim Tarihi:24.07.2023. İnternet Adresi: <http://acibadem.com.tr/ilgi-alani/gliomlar/>
- URL-6 Aras, Y. (2022). What are the types of brain tumors? Erişim Tarihi: 30.12.2024. İnternet Adresi: <https://kolanhastanesi.com.tr/saglik-rehberi/beyin-tumoru-turleri-nelerdir>
- URL-7 Acıbadem Web ve Yayın Kurulu (2024). Hipofiz Tümörleri Belirtileri, Tanı ve Tedavi Yöntemleri. Erişim Tarihi: 31.12.2024. İnternet Adresi: <https://www.acibadem.com.tr/ilgi-alani/hipofiz-tumoreri/>
- URL-8 Muneeb ul Hassan. (2018). VGG16 – Sınıflandırma ve Tespit için Evrişimli Ağ. Erişim Tarihi: 01.01.2025 İnternet Adresi: <https://neurohive.io/en/popular-networks/vgg16/>
- URL-9 Thite, A. (2024). Introduction to VGG16|What is VGG16? Erişim Tarihi: 01.01.2025 İnternet Adresi:<https://www.mygreatlearning.com/blog/introduction-to-vgg16/>
- URL-10 Amerikan Klinik Onkoloji Derneği-ASCO. (2021). Erişim Tarihi: 09.03.2023 İnternet Adresi:<https://beta.asco.org/>

URL-11 Ay, Ş. (2020). Evaluating Model Performance-Metrics. Erişim Tarihi:25.07.2023. İnternet Adresi: <https://medium.com/deep-learning-turkiye/model-performans%C4%B1n%C4%B1-de%C4%9Ferlendirmek-metrikler-cb6568705b1>

URL-12 About Keras 3. (2025). Erişim Tarihi: 04.02.2025. İnternet Adresi: <https://keras.io/about/>

URL-13 Math & Physics with Gus (2023). CNN Brain Tumor Classification. Date of Access:12.08.2023, from <https://www.kaggle.com/code/guslovesmath/cnn-brain-tumor-classification-99-accuracy>



URL-14 Bhuvaji S. (2020). Brain Tumor Classification (MRI). Date of Access:12.08.2023, from <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>



## EKLER

### Ek- 1: Etik Kurul Onayı

Evrak Tarih ve Sayısı: 07.06.2022-8988



T.C.  
FIRAT ÜNİVERSİTESİ  
GİRİŞİMSEL OLMAYAN ARAŞTIRMALAR  
ETİK KURULU  
GİRİŞİMSEL OLMAYAN ARAŞTIRMALAR  
ETİK KURULU KARARLARI

Oturum Tarihi	Oturum Saati	Oturum Sayısı
07.06.2022	14:00	2022/ 08- 03

Girişimsel Olmayan Araştırmalar Etik Kurulu 07.06.2022 tarihinde saat 14:00'da Kurul Başkanı Prof. Dr. Mustafa KAPLAN başkanlığında, aşağıda imzaları bulunan kurul üyelerinin katılımlarıyla toplanarak gündemdeki konuları görüşmüş ve aşağıdaki kararları almıştır:

Sorumlu Araştırmacı : Doç. Dr. Buket KAYA  
Diğer Araştırmacılar : Dok. Öğr. Aynur SEVINÇ, Uzm. Dr. Mehmet ÇİÇEKÇİ

**"Beyin Tümörünün Bilgisayarlı Tomografi Görüntüleri Üzerinden Derin Öğrenme Yaklaşımıyla Teşhisi ve Sınıflandırılması"** konulu tez çalışması 16/09/2021 tarihinde 2021/ 09-06 nolu kararla tarafımızca onaylanmıştır.

Sorumlu araştırmacının 26.05.2022 tarih ve 183969 sayılı dilekçesinde belirtildiği üzere; Uzm. Dr. Mehmet ÇİÇEKÇİ'nin çalışmaya katılması isteğinin uygun olduğuna oy birliğiyle karar verilmiştir.

*(Araştırmacının tüm süreçlerinde kurum ve kuruluşlardan gereken izinlerin alınmasından araştırmacılar sorumludur.)*

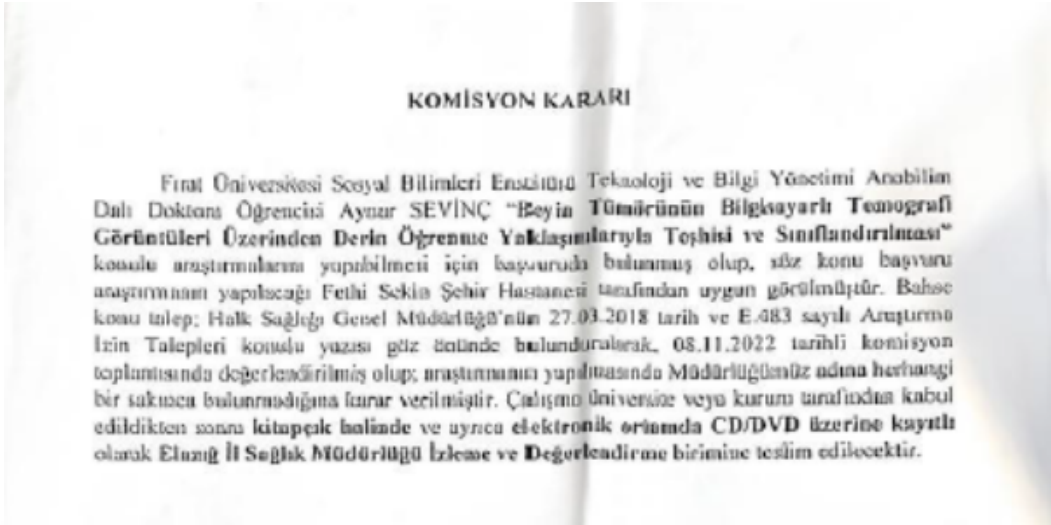
**Kurul Üyeleri:**  
Prof. Dr. Mustafa KAPLAN, Prof. Dr. Demet ÇİÇEK (Bulunmadı), Prof. Dr. Sevil YILMAZ (Bulunmadı), Doç. Dr. Nevzat GÖZEL , Doç. Dr. Uğur DEVECİ, Doç. Dr. Fazilet ERMAN, Doç. Dr. Burcu GÜL, Dr. Öğr. Üyesi Turgay BÖRK, Dr. Öğr. Üyesi Adem GÖK, Dr. Öğr. Üyesi Merve YILMAZ BOZOĞLAN

Prof. Dr. Mustafa KAPLAN  
Kurul Başkanı

Doç. Dr. Nevzat GÖZEL	Doç. Dr. Uğur DEVECİ
Doç. Dr. Fazilet ERMAN	Doç. Dr. Burcu GÜL
Dr. Öğr. Üyesi Turgay BÖRK	Dr. Öğr. Üyesi Adem GÖK
Dr. Öğr. Üyesi Merve YILMAZ BOZOĞLAN	

### Ek 1. Etik Kurul İzni

**Ek- 2: T.C Sağlık Bakanlığı Elazığ İl Sağlık Müdürlüğü Komisyon Kararı**



**Ek 1. T.C. Sağlık Bakanlığı Elazığ İl Müdürlüğü Komisyon Kararı**