

T.C.
AKDENİZ ÜNİVERSİTESİ



**DERİN ÖĞRENME UYGULAMASI DESTEKLİ PEKİŞTİRMELİ ÖĞRENME
ALGORİTMASI İLE BEYİN KANSERİLERİ TANI VE
SINIFLANDIRILMASINDA ARAYÜZ OLUŞTURULMASI**

Seda ARIKAN

**FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

ŞUBAT 2025

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ



**DERİN ÖĞRENME UYGULAMASI DESTEKLİ PEKİŞTİRMELİ ÖĞRENME
ALGORİTMASI İLE BEYİN KANSERİLERİ TANI VE
SINIFLANDIRILMASINDA ARAYÜZ OLUŞTURULMASI**

Seda ARIKAN

**FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

ŞUBAT 2025

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DERİN ÖĞRENME UYGULAMASI DESTEKLİ PEKİŞTİRMELİ ÖĞRENME
ALGORİTMASI İLE BEYİN KANSERİLERİ TANI VE
SINIFLANDIRILMASINDA ARAYÜZ OLUŞTURULMASI**

**Seda ARIKAN
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

ŞUBAT 2025

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME UYGULAMASI DESTEKLİ PEKİŞTİRMELİ ÖĞRENME
ALGORİTMASI İLE BEYİN KANSERİLERİ TANI VE
SINIFLANDIRILMASINDA ARAYÜZ OLUŞTURULMASI

Seda ARIKAN
BIYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 04/03/2025 tarihinde jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.

Doç. Dr. Çiğdem Saraç (Danışman)
Prof. Dr. Hüseyin Özgür Kazancı
Dr. Öğr. Üyesi Onur Koçak

ÖZET

DERİN ÖĞRENME UYGULAMASI DESTEKLİ PEKİŞTİRMELİ ÖĞRENME ALGORİTMASI İLE BEYİN KANSERİLERİ TANIMA VE SINIFLANDIRILMASINDA ARAYÜZ OLUŞTURULMASI

Seda ARIKAN

Yüksek Lisans Tezi, Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Çiğdem SARAÇ

Eş Danışman: Doç. Dr. Yiğit Ali ÜNCÜ

Şubat 2025; 73 sayfa

Beyin kanseri, beyin dokusunda kontrolsüz büyüyen tümörlerin neden olduğu ciddi bir hastalıktır. Bu hastalık baş ağrısı, mide bulantısı, kusma, denge kaybı ve nörolojik bozukluklar gibi çeşitli belirtilerle kendini göstermektedir. Tedavi süreci, tümörün türüne ve hastanın genel sağlık durumuna bağlı olarak cerrahi müdahale, radyoterapi, kemoterapi ve hedefe yönelik ilaç tedavilerini içerebilir. Beyin tümörlerinin tanısında Manyetik Rezonans Görüntüleme (MRI) önemli bir rol oynamaktadır. MRI, yüksek çözünürlüklü görüntüler sağlayarak tümörlerin tespit edilmesini ve değerlendirilmesini mümkün kılmaktadır. Medikal görüntü işleme, tıbbi görüntülerin analiz edilmesi ve yorumlanması için kullanılan dijital teknikler bütünüdür. Son yıllarda ise yapay zeka, derin öğrenme ve pekiştirmeli öğrenme gibi yöntemler bu süreçlerde büyük ilerleme sağlamıştır. Fakat literatürde derin öğrenme mimarileri ve pekiştirmeli öğrenme algoritmasının birlikte kullanıldığı çalışmalara rastlanılmamaktadır. Bu nedenle bu çalışmanın temel amacı derin öğrenme ve pekiştirmeli öğrenme yöntemlerini kullanarak MRI verilerinden primer beyin tümörlerini sınıflandırmak için otomatik bir tanı sistemi geliştirmektir. Bu amaç doğrultusunda, çalışmada, beyin kanserleri sınıflandırılması için derin öğrenme mimarileri destekli Q-öğrenme algoritmasıyla bir sistem geliştirilmiş ve Matlab ortamında, üç farklı veri seti kullanılarak primer beyin tümörleri MR görüntüleri sınıflandırılmıştır. Q-öğrenme algoritması ile çalışan bu model ile VGG16 mimarisinde %97.45 doğruluk, Resnet50 mimarisinde %96.06 doğruluk, DenseNet201 mimarisinde ise %96.93 doğruluk oranı elde edilmiştir. Sonuçlar geliştirilen modelin beyin tümörü sınıflandırmasında umut vadettiğini göstermektedir. Ayrıca tanıda hekimlere daha hızlı ve güvenilir bir teşhis süreci için sistem arayüz ile desteklenmiştir. Bu çalışmanın temel amacı, beyin tümörü teşhis sürecinde otomatik bir tanı sistemi geliştirmek ve bu sistemi hekimlere teşhis ve tedavi planlama süreçlerinde yardımcı olacak bir karar destek aracı haline getirmektir. Çalışma sonunda elde edilen sonuçlar, geliştirilen modelin teşhis doğruluğunu önemli ölçüde artırdığını ve klinik uygulamalarda geniş bir kullanım potansiyeline sahip olduğunu göstermektedir.

ANAHTAR KELİMELELER: Beyin Kanseri, Derin Öğrenme, Pekiştirmeli Öğrenme

Yapay Zeka

JÜRİ: Doç. Dr. Çiğdem Saraç (Danışman)

Prof. Dr. Hüseyin Özgür Kazancı

Dr. Öğr. Üyesi Onur Koçak



ABSTRACT

DEVELOPMENT OF INTERFACE FOR THE DIAGNOSIS AND CLASSIFICATION OF BRAIN CANCERS WITH REINFORCEMENT LEARNING ALGORITHM SUPPORTED BY DEEP LEARNING APPLICATION

Seda ARIKAN

MSc Thesis in Biomedical Engineering

Supervisor: Assoc. Prof. Dr. Çiğdem SARAÇ

Co-Supervisor: Assoc. Prof. Dr. Yigit Ali ÜNCÜ

February 2025; 73 pages

Brain cancer is a severe condition resulting from the uncontrolled proliferation of tumors within brain tissue. It manifests through various symptoms, including headaches, nausea, vomiting, balance issues, and neurological impairments. Treatment approaches vary based on tumor type and the patient's overall health and may involve surgery, radiotherapy, chemotherapy, or targeted drug therapies. Magnetic Resonance Imaging (MRI) is a crucial tool in detecting and diagnosing brain tumors. MRI provides high-resolution images, making it possible to detect and evaluate tumors. Medical image processing is a set of digital techniques used to analyze and interpret medical images. In recent years, methods such as artificial intelligence, deep learning and reinforcement learning have made great progress in these processes. In the literature, there have been no research where deep learning architectures and reinforcement learning algorithms are used together. The primary objective of this study is to design an automated diagnostic system for classifying primary brain tumors from MRI images by integrating deep learning and reinforcement learning techniques. To achieve this, a classification system utilizing a Q-learning algorithm in combination with deep learning architectures was developed. Within the Matlab environment, MR images of primary brain tumors were analyzed using three distinct datasets. The proposed model, incorporating the Q-learning algorithm, achieved an accuracy of 97.45% with the VGG16 architecture, 96.06% with ResNet50, and 96.93% with DenseNet201. The findings indicate that the proposed model demonstrates strong potential for brain tumor classification. In addition, the system was supported with an interface for a faster and more reliable diagnostic process for physicians.

KEYWORDS: Artificial Intelligence, Brain Cancer, Deep Learning, Reinforcement Learning

COMMITTEE: Assoc. Prof. Dr. ıgdem SARAÇ (Supervisor)

Prof. Dr. Hseyin zgr KAZANCI

Asst. Prof. Dr. Onur Koak



ÖNSÖZ

Tez çalışmam boyunca beni cesaretlendiren, sabrı, eleştirileri, rehberliği ve yapıcı yönlendirmeleriyle akademik gelişimime büyük katkı sağlayan değerli danışmanım Doç. Dr. Çiğdem GÖKÇEK-SARAÇ'a en içten teşekkürlerimi sunarım. Engin bilgi birikimi, vizyonu ve akademik disiplini, bu alana olan ilgimi arttırarak, bilimsel düşünme becerilerimi geliştirmeme de büyük katkı sağlamıştır. Yalnızca akademik süreçte değil, aynı zamanda bilim insanı olma yolculuğumda da bana ilham vermiş, sabrı ve anlayışıyla bu süreci daha verimli ve anlamlı kılmıştır. Hem bilimsel rehberliği hem de sıcak ve destekleyici yaklaşımı için kendisine sonsuz teşekkürlerimi sunarım.

Tez süresince bilgileriyle rehberlik eden ve tecrübeleriyle katkı sağlayan eş danışman hocam Doç. Dr. Yiğit Ali Üncü'ye desteklerinden dolayı çok teşekkür ederim.

Tez çalışmam boyunca beni destekleyen, bilgi birikimini paylaşan, tüm streslerimi yumuşatan, sabrıyla bıkmadan beni dinleyen kuzenim Çağan Hatapçı'ya ve değerli arkadaşım Muratcan Ülker'e teşekkür ederim.

Tüm çalışmam da beni canı gönülden destekleyen, sevgisiyle sabrıyla motivasyon sağlayan, hep gurur duyduğunu hissettiren, başaracağıma hep inanan ve arkamda olan eşim Çağdaş Arıbal'a teşekkür ederim.

En önemlisi hep benimle gurur duyan, sevgisiyle, bilgeliğiyle, yaşam rehberim olan, okumayı okuyanı okutanı övgüyle karşılayan canım babam Süleyman Arıkan'a, hep cesaretlendiren, pes etmeme izin vermeyen, karanlıkta ışığım canım annem Leyla Arıkan'a ve hep yanımda olan, yapabilirsin diyerek her zaman motive eden canım yeğenim İklimnaz Gökçe'ye çok teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	iii
ÖNSÖZ	v
AKADEMİK BEYAN	viii
SİMGELER VE KISALTMALAR.....	ix
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ	xii
1. GİRİŞ	1
2. KAYNAK TARAMASI.....	3
2.1. Beyin ve Beyin Tümörleri.....	3
2.1.1. Beyin Tümörlerinin Epidemiyolojisi	4
2.1.2. Beyin Tümörlerinin Etiyolojisi	5
2.2. Beyin Tümörlerinin Görüntülenmesi ve Tanısı	5
2.3. Yapay Zeka	9
2.3.1. Veri Kaynakları.....	10
2.3.2. Veri Toplama Teknikleri.....	11
2.3.3. Makine Öğrenmesi	13
2.3.4. Derin Öğrenme.....	23
2.4. Literatürden Örnekler.....	31
3. MATERYAL VE METOT	35
3.1. Veri Seti ve Ön işleme	35
3.2. Veri Ayırma Süreci	35
3.3. Görüntü Çeşitliliği ve Veri Artırma	36
3.4. Model Mimarisinin Geliştirilmesi.....	36
3.5. Denetimli Öğrenme Süreci.....	38
3.6. Pekiştirmeli Öğrenme ve Q-tablosu Oluşturma	39
4. BULGULAR.....	41
4.1. Veri Seti Oluşturma.....	41
4.2. Model Eğitimi	43
4.3. Q Tablosu Oluşturma ve Tahmin.....	52
5. TARTIŞMA	56

6. SONUÇLAR	60
7. KAYNAKLAR	62
ÖZGEÇMİŞ	



AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Derin Öğrenme Uygulamasın Destekli Pekiştirmeli Öğrenme Algoritması ile Beyin Kanserileri Tanı ve Sınıflandırılmasında Arayüz Oluşturulması” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

27/03/2025

Seda ARIKAN

İmzası

SİMGELER VE KISALTMALAR

Simgeler

. : Ondalık ayırıcı

× : Matris çarpanı

Kısaltmalar

API : Uygulama Programlama Arayüzü

BT : Bilgisayarlı Tomografi

DAG : Difüzyon Ağırlıklı Görüntüleme

DÖ : Derin öğrenme

DQA : Derin Q-Ağları

DSÖ : Dünya Sağlık Örgütü

DVR : Destek vektör regresyonu

EGFR : Epidermal Büyüme Faktör Reseptörü

ESA : Evrişimli Sinir Ağları

FLAIR : Sıvıyla Zayıflatılmış İnversiyon Kurtarma Görüntülemesi

fMRI : Fonksiyonel Manyetik Rezonans Görüntüleme

GBM : Glioblastoma Multiforme

GN : Gerçek Negatif

GP : Gerçek Pozitif

IDH : İzositrat DeHidrogenaz

IoT : Nesnelerin İnterneti

MGMT : O6-metilguanin-DNA metiltransferaz

ML : Makine Öğrenimi

MÖ : Makine Öğrenmesi

MR : Manyetik Rezonans

MRI : Manyetik Rezonans Görüntüleme

MRPI : Manyetik Rezonans Parmak İzi

MSS : Merkezi sinir sistemi

PET : Pozitron Emisyon Tomografisi

ReLU : Rektifiye Lineer Ünite

RF : Radyo Frekans

YN : Yanlış Negatif

YP : Yanlış Pozitif

YSA : Yapay Sinir Ağları

YZ : Yapay Zeka

ŞEKİLLER DİZİNİ

Şekil 2.1. Beyin Bölümleri.....	3
Şekil 2.2. Primer tümörlere ait MR görüntüleri.....	7
Şekil 2.3. MR görüntüleme sistemi çalışma mekanizması.....	8
Şekil 2.4. Yapay zeka, makine öğrenmesi, derin öğrenme arasındaki ilişki.....	10
Şekil 2.5. Makine öğrenmesi alt dalları.....	14
Şekil 2.6. Denetimli öğrenme çalışma mekanizması.....	15
Şekil 2.7. Denetimsiz öğrenme çalışma mekanizması.....	16
Şekil 2.8. Pekiştirmeli öğrenme çalışma mekanizması.....	16
Şekil 2.9. Derin Q- Öğrenme çalışma prensibi.....	18
Şekil 2.10. Makine Öğrenmesi ve Derin Öğrenme karşılaştırması.....	25
Şekil 2.11. Standart bir VGG-16 Ağ Mimarisi.....	26
Şekil 2.12. Resnet 50 mimarisinin temel yapısı.....	26
Şekil 2.13. DenseNet-201 Mimarisi.....	27
Şekil 2.14. Karışıklık matrisi.....	30
Şekil 4.1. Veri setlerinin eğitim, test ve doğrulama olarak bölünmesi.....	41
Şekil 4.2. Tümör türlerinin eğitim, doğrulama ve test kümeleri grafikleri.....	41
Şekil 4.3. Ön işleme adımları sonrasında Mr görüntüsü.....	42
Şekil 4.4. VGG 16 sonuç grafiği	44
Şekil 4.5. ResNet50 sonuç grafiği	46
Şekil 4.6. DenseNet201 eğitim sonucu.....	47
Şekil 4.7. VGG-16 test (a) ve eğitim (b) karışıklık matrisleri	48
Şekil 4.8. ResNet50 test (a) ve eğitim (b) karışıklık matrisleri	49
Şekil 4.9. DenseNet201 test (a) ve eğitim (b) karışıklık matrisleri	49
Şekil 4.10. Glioma tahmin sonuçları	51
Şekil 4.11. Pitiutary tahmin sonuçları	51

Şekil 4.12. Sağlıklı (No tomur) tahmin sonuçları.....	52
Şekil 4.13. Meningioma tahmin sonuçları	52



ÇİZELGELER DİZİNİ

Çizelge 2.1. ESA mimarileri karşılaştırılması.....	28
Çizelge 4.1. Çalışmada kullanılan tümör çeşitleri ve sayıları.....	40
Çizelge 4.2. Her bir tümör türünün eğitim, doğrulama ve test olarak ayrımı.....	41
Çizelge 4.3. Mimarilerin doğruluk değerleri, F1 skor değerleri ve öğrenme süreleri karşılaştırılması	48



1. GİRİŞ

Beyin, merkezi sinir sisteminin yönetim merkezi olarak insan vücudundaki en karmaşık ve hayati organlardan biridir. Sinir hücreleri (nöronlar) ve glial hücrelerden meydana gelen bu yapı; motor kontrol, bilişsel işlevler ve yaşam için kritik öneme sahip süreçleri yönetmektedir (Louis vd., 2016). Ancak beyin, tümörler gibi ciddi sağlık sorunlarına karşı savunmasızdır. Beyin tümörleri, hücrelerin anormal büyümesi sonucu meydana gelmektedir ve malign (kötü huylu) ya da benign (iyi huylu) olarak sınıflandırılmaktadır. Merkezi sinir sistemini (MSS) oluşturan beyin ve omurilikte, 120'den fazla farklı tümör tipi tespit edilmiştir (Louis vd., 2016; Brat vd., 2018). Yetişkinlerde en yaygın görülen birincil beyin tümörleri arasında, MSS'deki glial hücrelerden kaynaklanan gliomlar, beyin ve omuriliği çevreleyen meninkslerden kaynaklanan meningiomlar ve hipofiz bezinde gelişen hipofiz tümörleri (pituitary) yer almaktadır (Molinaro vd., 2019; Wiemels vd., 2010). Gliomlar, malignite potansiyeline en çok sahip olabilen ve çoğunlukla agresif bir şekilde büyüyen tümörlerdir. Meningiomlar ise genellikle iyi huylu tümörler olup beyin zarından gelişmektedir. Hipofiz tümörleri ise hormonal dengesizliklere yol açıp, hipofiz bezinin işlevlerini etkilemektedir (Miller vd., 2021).

Beyin tümörlerinin teşhisinde Manyetik Rezonans Görüntüleme (MRI), yüksek çözünürlüklü görüntüler sağlayarak güvenilir bir yöntem olarak kabul edilmektedir. MRI, tümörlerin boyutunu, sınırlarını ve çevre dokularla olan ilişkisini ayrıntılı olarak göstermektedir. Gadolinyum bazlı kontrast maddelerle desteklenen MR görüntüleme, malign tümörlerin damarsal yapılarını incelemeye de kritik bir rol oynamaktadır (Idiculla vd., 2020; Miller vd., 2021). Ancak, MR görüntülerinin analizi zaman alıcıdır ve uzmanlık gerektirmektedir. Bu nedenle, tıbbi görüntü işleme teknolojilerinde hızlı ve güvenilir sonuç elde etme ihtiyacı doğmaktadır.

Son yıllarda Yapay Zeka (YZ) ve Makine Öğrenimi (ML), karmaşık görevler ve kararlar için kullanılan teknolojiler arasında önemli bir yer edinmektedir (Rajpurkar vd., 2022). Makine öğrenimi sayesinde algoritmalar verilerden öğrenme yeteneğine sahip olur ve bu şekilde tahminlerde bulunabilir hale gelmektedir. Derin öğrenme (DL) ise makine öğreniminin bir alt alanı olarak büyük veri setlerinden anlamlı desenler çıkarmada uzmanlaşır ve bu alandaki gelişimi arttırır (Rajpurkar vd., 2022; Esteva vd., 2017). Özellikle Evrişimli Sinir Ağları (ESA) gibi derin öğrenme mimarilerinin kullanımıyla medikal görüntülerde segmentasyon ve sınıflandırma alanında önemli ilerlemeler kaydedilmektedir (Esteva vd., 2017). Örneğin ResNet (Artık Ağ) ve DenseNet (Yoğun Bağlantılı Evrişimsel Ağlar) gibi modeller çok yüksek doğruluk oranları sunarak beyin tümörlerini sınıflandırmada önemli bir rol oynamaktadır (He vd., 2016; Huang vd., 2017). Derin öğrenme algoritmaları hem tanı sürecini hızlandırıp hem de uzman hatalarını azaltarak medikal görüntülerin otomatik analizini sağlamaktadır (Huang vd., 2017). Ayrıca ML öğreniminin alt dalı olan denetimli öğrenme, tıbbi görüntülerde tümörlü ve tümörsüz alanların doğru şekilde sınıflandırma yeteneği sağlamaktadır (Litjens vd., 2017). Denetimsiz öğrenme ise hasta gruplarını genetik benzerliklere göre kümelendirirken, pekiştirmeli öğrenme, ödül-ceza mekanizmasına dayalı olarak çalışır ve örneğin cerrahi robotların hassasiyetini arttırmak gibi uygulamalarda kullanılmaktadır (Benjamens vd., 2020; Uwimana vd., 2025).


Bu tez çalışmasında, MRI görüntülerinden beyin tümörü sınıflandırmasını gerçekleştirmek için derin öğrenme ve pekiştirmeli öğrenme yöntemlerinin bir arada kullanıldığı yenilikçi bir yaklaşım geliştirilmiştir. Çalışmada, derin öğrenme algoritmaları olarak VGG16, ResNet50 ve DenseNet201 mimarileri kullanılmıştır. VGG16, sade yapısıyla temel bir model sunarken, ResNet50 daha derin ağlarda öğrenme problemlerini çözmektedir (He vd., 2016). DenseNet201 ise katmanlar arasındaki yoğun bağlantılar sayesinde özellik paylaşımını optimize ederek daha verimli bir model sağlamaktadır (Huang vd., 2017). Bu üç mimarinin doğruluk, hız ve genelleştirme kapasiteleri geniş bir MRI veri seti üzerinde karşılaştırılmıştır. Çalışmada ayrıca, teşhis sürecinin daha esnek ve uyarlanabilir hale getirilmesi amacıyla Q-Öğrenme algoritmasından yararlanılmıştır. Pekiştirmeli öğrenme algoritmalarından biri olan Q-Öğrenme, ödül ve ceza mekanizmalarını kullanarak karmaşık tanı süreçlerinde etkin kararlar alınmasını sağlamaktadır (Sutton & Barto, 2018; Litjens vd., 2017). Derin Q-Öğrenme ise sinir ağlarının yüksek boyutlu veri setlerindeki güçlü öğrenme kapasitesinden yararlanarak dinamik karar destek sistemleri için ideal bir araç sunmaktadır (Litjens vd., 2017). Bu kapsamda, Q-Öğrenme algoritması MRI görüntülerine uygulanarak tanı modellerinin performansı değerlendirilmiştir.

Bu çalışmanın temel amacı, derin öğrenme ve pekiştirmeli öğrenme yöntemlerini kullanarak MRI verilerinden primer beyin tümörlerini sınıflandırmak için otomatik bir tanı sistemi geliştirmektir. Böylelikle, geliştirilen sistemin hekimlere teşhis ve tedavi planlama süreçlerinde yardımcı olacak bir karar destek aracı olarak kullanılması hedeflenmiştir. Çalışma sonunda elde edilen sonuçlar, geliştirilen modelin teşhis doğruluğunu önemli ölçüde artırdığını ve klinik uygulamalarda geniş bir kullanım potansiyeline sahip olduğunu göstermektedir.

2. KAYNAK TARAMASI

2.1. Beyin ve Beyin Tümörleri

Beyin, merkezi sinir sisteminin temel yapıtaşı olup bilişsel, motor ve otonom sinir sistemi işlevlerinin kontrol merkezidir. Bilişsel işlevler düşünme, hafıza ve öğrenme gibi yüksek beyin işlevlerini içerirken, motor işlevler vücut hareketlerini kontrol ve koordine eden sistemleri içerir. Otonom sinir sistemi kalp atışı, solunum ve sindirim gibi istemsiz vücut fonksiyonlarını düzenler. Yapısal olarak beyin, sinir hücreleri (nöronlar) ve destek hücreleri (glial hücreler) içerir. Nöronlar elektriksel ve kimyasal sinyaller yoluyla bilgi iletir. Glial hücreler ise nöronları destekler, besin sağlar, atıkları temizler ve sinirsel iletimi kontrol eder. Beyin frontal, temporal, parietal ve oksipital loblardan oluşmaktadır (Şekil 2.1). Frontal lob düşünme, planlama, hareket kontrolü ve kişilik özellikleri gibi bilişsel işlevlerden sorumludur. Parietal lob duyuusal bilgileri işler, vücut duyularını (dokunma, sıcaklık, ağrı) ve uzamsal farkındalığı sağlar. Temporal lob hafıza, dil, işitsel işlevler ve bazı duygusal tepkilerle ilişkilidir. Oksipital lob görsel bilginin işlenmesinden sorumludur. Bu loblar arasındaki etkileşimler ve tamamlayıcı işlevler, beynin karmaşık yapısının ve yüksek işlevselliğinin temel görevleridir.



Şekil 2.1. Beyin Bölümleri (Üngüren, 2016).

Beyin tümörleri, iyi huylu (benign) ve kötü huylu (malign) olarak iki ana kategoriye ayrılmaktadır. Bu sınıflandırma, tümörlerin biyolojik davranışlarını ve tedavi stratejilerini doğrudan etkilemektedir. Örneğin, meningiomlar genellikle benign tümörler arasında yer alırken, glioblastomlar gibi gliomlar agresif bir malignite göstermektedir (Weller vd., 2015). Glial hücrelerin anormal büyümesi, gliomlar gibi beyin tümörlerinin oluşumuna yol açmaktadır. Meningiomlar meninkslerden kaynaklanırken, hipofiz tümörleri hipofiz bezinde gelişmektedir. Dünya Sağlık Örgütü (DSÖ), beyin tümörlerini malignite derecelerine göre sınıflandırmış ve bu sınıflandırma klinik yaklaşımların temelini oluşturmaktadır (Louis vd., 2016). Gliomlar, malign beyin tümörlerinin büyük bir kısmını oluşturmakta ve genetik, çevresel ve biyolojik faktörlerin karmaşık etkileşimleri sonucu ortaya çıkmaktadır (Goodenberger & Jenkins, 2012). Ayrıca, gliomların gelişiminde hücrel kökenler ve mikroçevre belirleyici bir rol oynamaktadır (Zong vd., 2012). Ancak, beyin tümörlerinin heterojen yapıları, sınırlı tedavi seçenekleri, teşhis ve tedavi süreçlerini karmaşık hale getirmektedir (Ostrom vd., 2014). Bu nedenle,

beyin tümörlerinin biyolojik mekanizmalarının daha iyi anlaşılması ve yeni teşhis ile tedavi yaklaşımlarının geliştirilmesi, klinik uygulamalar açısından büyük önem taşımaktadır.

Primer beyin tümörleri doğrudan beyinde veya omurilikte gelişen tümörlerdir ve kaynaklandıkları hücre tipine göre sınıflandırılır. Bu tümörlerin başlıca türleri şunlardır:

Gliomlar: Glial hücrelerden kaynaklanan bu tümörler, kötü huylu beyin tümörlerinin %80'ini oluşturan en yaygın primer tümörlerdir. Gliomlar, astrositom, oligodendrogliom ve ependimom gibi alt türlere ayrılır. Ayrıca genetik ile çevresel faktörlerin karmaşık etkileşimleri sonucu oluşur (Louis vd., 2016).

Meningiomlar: Beyin ve omuriliği çevreleyen meninkslerden kaynaklanan bu tümörler genellikle benign olarak sınıflandırılır. Ancak büyüklükleri ve konumları, nörolojik semptomlara yol açarak cerrahi müdahale gerektirebilir (Ostrom vd., 2014).

Hipofiz Tümörleri: Hipofiz bezinde gelişen bu tümörler, hormonal bozukluklara neden olabilir. Genellikle benign olmasına rağmen, hormon üretimini artırarak veya azaltarak ciddi klinik tablolara yol açabilir (Weller vd, 2015).

Medulloblastomlar: Çocuklarda daha sık görülen bu yüksek dereceli tümörler, beyincikte oluşur. Medulloblastomlar hızlı büyüme gösterir ve erken teşhisle agresif tedavi gerektirir. Bu tümörler, pediatrik onkolojide en çok dikkat edilen malignitelerden biridir (Goodenberger & Jenkins, 2012).

Sekonder beyin tümörleri ise vücudun başka bir bölgesinden, genellikle akciğer, meme veya deri gibi organlardan beyine metastaz yoluyla yayılan tümörlerdir. Bu tür tümörler, yetişkinlerde en sık görülen malign beyin tümörü türünü oluşturmaktadır (Ostrom vd., 2021).

2.1.1. Beyin Tümörlerinin Epidemiyolojisi

Beyin tümörleri, dünya genelinde her 100.000 kişiden birinde görülmekte olup, önemli bir sağlık sorunu oluşturmaktadır. ABD'de her yıl yaklaşık 24.000 primer beyin tümörü teşhisi konulmaktadır. Bu vakaların önemli bir kısmını malign gliomlar, özellikle Glioblastoma Multiforme (GBM) oluşturmaktadır (Louis vd., 2021; Ostrom vd., 2021). GBM, en agresif ve ölümcül beyin tümörlerinden biri olarak öne çıkmakta ve tedaviye karşı direnç göstermesi nedeniyle klinik yönetimde ciddi zorluklar sunmaktadır (Grochans vd., 2022).

Malign Glioblastoma gibi tümörler, yüksek mortalite oranlarıyla dikkat çekerken, meningiom gibi benign tümörler genellikle daha iyi bir prognoza sahiptir. Cinsiyet farkları da önemli bir rol oynamaktadır; meningiomlar kadınlarda daha sık görülürken, glioblastoma gibi malign gliomlar erkeklerde daha yaygındır (Grochans vd., 2022). Beyin tümörlerinin görülme sıklığı yaşla birlikte artış göstermekte ve çocukluk çağı kanserlerinin yaklaşık %25'ini primer beyin tümörleri oluşturmaktadır (Johnson vd., 2014; Bray vd., 2018). Bu istatistikler, beyin tümörlerinin demografik özellikleri için yaşa bağlı risk faktörlerinin, teşhis ve tedavi süreçlerini etkileyen kritik unsurlar olduğunu göstermektedir.

2.1.2. Beyin Tümörlerinin Etiyolojisi

Beyin tümörlerinin oluşumuna yol açan kesin sebepler tam olarak bilinmemektedir. Genetik yatkınlık ve çevresel etkenlerin bu süreçte etkili olduğu düşünülmektedir. Genetik faktörler arasında Li-Fraumeni Sendromu ve Turcot Sendromu gibi kalıtsal sendromlar, beyin tümörlerinin gelişme riskini artıran kritik unsurlar olarak öne çıkmaktadır (Louis vd., 2016). Çevresel etkenler arasında ise iyonlaştırıcı radyasyona maruz kalma ve belirli kimyasallarla uzun süreli temas, tümör gelişimi açısından risk faktörleri olarak tanımlanmıştır (Ostrom vd., 2021). Bunun yanında, İzositrat Dehidrogenaz (IDH) mutasyonu ve Epidermal büyüme faktör reseptör (EGFR) amplifikasyonu gibi moleküler değişiklikler, özellikle gliomların oluşumunda, ilerlemesinde belirleyici genetik anormalliklerdir (Goodenberger & Jenkins, 2012). Beyin tümörlerinin semptomları, tümörün büyüklüğü, bulunduğu bölge ve büyüme hızı gibi faktörlere bağlı olarak çeşitlilik göstermektedir. Nörolojik belirtiler arasında baş ağrısı, nöbetler, motor fonksiyon kaybı ve duyu bozuklukları sıklıkla görülmektedir (Weller vd., 2015). Bunların yanı sıra, bilişsel ve davranışsal değişiklikler, konsantrasyon güçlüğü, hafıza kaybı ve kişilik değişiklikleri şeklinde kendini gösterebilmektedir (Zong vd., 2012). Görme ve işitme sorunları, çift görme, görme kaybı ve işitme kaybı gibi belirtileri içermekteyken; hipofiz tümörleri gibi durumlarda hormonal dengesizlikler de yaygın olarak karşılaşılan semptomlar arasında yer almaktadır (Louis vd., 2016).

2.2. Beyin Tümörlerinin Görüntülenmesi ve Tanısı

Beyin tümörlerinin tanısı, kapsamlı ve çok yönlü bir değerlendirme süreci gerektirir. Bu süreçte, hastanın klinik belirtileri detaylı bir şekilde analiz edilir ve ileri görüntüleme teknikleri ile biyokimyasal testler bir araya getirilerek tümörün türü, malignite derecesi ve yerleşimi hakkında bilgi sağlanır. Modern tıp uygulamalarında, aşağıda sıralanan yöntemler, beyin tümörlerinin tanısında en sık başvurulan teknikler arasında yer almaktadır.

Nörolojik muayene, beyin tümörlerinin neden olduğu klinik semptomların değerlendirilmesinde ilk ve önemli bir adımdır. Bu muayene, hastanın refleksleri, kas gücü, duyu algısı, denge ve koordinasyon gibi motor ve duyu işlevlerini kapsamlı bir şekilde analiz eder. Anormal refleks bulguları, beyindeki sinir yollarının etkilenmiş olabileceğine işaret edebilir (Weller vd., 2015). Denge ve koordinasyon testleri, beyincik veya beyin sapında bulunan tümörlerin varlığına dair ipuçları sunarken (Ostrom vd., 2021), kognitif testler, bellek, konsantrasyon ve dil işlevlerindeki bozulmalarla frontal lob tümörlerinin varlığı arasında bağlantı kurabilir (Goodenberger & Jenkins, 2012). Bununla birlikte, nörolojik muayene tümörün varlığına ilişkin genel bir değerlendirme sunmasına rağmen, tümörün tipi ve kesin konumu hakkında yeterli bilgi sağlamaz. Ancak, bu muayene ileri tanı yöntemleri için önemli bir rehber görevi görmektedir.

Bilgisayarlı Tomografi (BT), X-ışınları kullanarak beyin dokusunun iki boyutlu kesitsel görüntülerini sağlayan bir görüntüleme yöntemidir. Özellikle travmatik beyin hasarı ve akut kafa içi kanamalar gibi acil durumlarda hızlı görüntüleme sağlaması nedeniyle sıklıkla tercih edilmektedir (Jain, 2011). Bununla birlikte, BT'nin beyin tümörlerini değerlendirme açısından detay seviyesinin sınırlı olması, bu yöntemin

genellikle MRI'nın alternatifi olarak kullanılmamasına neden olmaktadır. BT'nin en büyük avantajlarından biri, hızlı uygulanabilirlik sunarak acil durumlarda zaman kaybını önlemesidir. Ayrıca, meningiom gibi tümörlerde görülen kalsifikasyonları MRI'ya kıyasla daha iyi tespit edebilme yeteneği, bu yöntemi belirli durumlar için ideal hale getirmektedir. Ancak, yumuşak doku ayrımı konusunda MRI kadar detaylı bilgi sunamaması ve iyonlaştırıcı radyasyon içermesi, BT'nin önemli dezavantajları arasında yer almaktadır (Boas vd., 2012; Jain, 2011).


Biyopsi, beyin tümörlerinin kesin teşhisini sağlamak amacıyla histopatolojik inceleme yapılmasını gerektiren bir yöntemdir. Bu işlem, genellikle stereotaktik biyopsi veya açık biyopsi tekniklerinden biriyle gerçekleştirilir. Stereotaktik biyopsi, görüntüleme teknikleri (MRI veya BT) yardımıyla bir iğne kullanılarak tümör dokusundan örnek alınmasıyla gerçekleştirilir ve özellikle tümörün tehlikeli ya da cerrahi müdahale yapılamayacak bölgelerde bulunduğu durumlarda tercih edilir (Rydelius, 2023). Açık biyopsi ise genellikle cerrahi bir işlem sırasında, tümörün tamamen çıkarılmasının planlandığı durumlarda uygulanır. Bu yöntem, histopatolojik analiz yoluyla tümörün hücresel yapısını, malignite derecesini (WHO Grade I-IV) ve türünü (örneğin glioblastoma, meningiom) belirlemede kritik bir rol oynamaktadır (Louis vd., 2016; Ostrom vd., 2019).

Moleküler testler, beyin tümörlerinin genetik ve moleküler özelliklerini değerlendirmek için kullanılan ileri düzey tanı yöntemleridir. Özellikle gliomlar gibi primer beyin tümörlerinin tedavi planlamasında kritik bir rol oynamaktadır. Bu testler, tümörlerin biyolojik yapısını daha iyi anlamaya ve hedefe yönelik tedavi stratejileri geliştirmeye olanak sağlar. Yaygın olarak incelenen genetik değişiklikler arasında IDH mutasyonu, 1p/19q kodelesyonu ve O6-metilguanin-DNA metiltransferaz (MGMT) promotör metilasyonu yer alır. IDH1 ve IDH2 mutasyonları, gliomlarda prognozun belirlenmesinde önemli bir biyobelirteç olarak öne çıkar. 1p/19q kodelesyonu, oligodendrogliomların tanısında kullanılır ve daha iyi bir tedavi yanıtıyla ilişkilendirilir. MGMT promotör metilasyonu ise glioblastomlarda temozolomid tedavisine duyarlılığı tahmin etmek için değerlendirilir. Moleküler testler, prognozun belirlenmesi ve bireyselleştirilmiş tedavi yaklaşımlarının geliştirilmesi açısından vazgeçilmez bir rol üstlenir (Molinaro vd., 2019).

Fonksiyonel görüntüleme teknikleri, beyin tümörlerinin konumunun çevre dokular üzerindeki etkisini değerlendirmek ve tümör yapısına ilişkin detaylı bilgi sağlamak için sıklıkla kullanılır. Fonksiyonel MRI (fMRI), beyindeki kan akışı değişikliklerini ölçerek fonksiyonel bölgelerin haritalanmasını sağlar (Bogomolny vd., 2004). Pozitron Emisyon Tomografisi (PET), tümör metabolizmasını değerlendirerek malignite derecesine dair bilgi sunar (Chen, 2007). Difüzyon Ağırlıklı Görüntüleme (DAG) ise su moleküllerinin difüzyonunu ölçerek tümör yapısını analiz eder (Kan vd., 2006). Bu tekniklerin yanı sıra MRI, tümör dokusunun boyutunu, yerleşimini ve çevre dokular üzerindeki etkisini değerlendirmede en yaygın kullanılan yöntemdir. Hem tanıda hem de tedavi planlamasında kritik bir araç olarak kabul edilmektedir (Bauer vd., 2013).

Manyetik Rezonans Görüntüleme (MRI), vücuttaki yumuşak dokuların detaylı ve non-invaziv bir şekilde görüntülenmesini sağlayan ileri bir tıbbi görüntüleme yöntemidir (Aswathy vd., 2014). İlk olarak 1970'lerde geliştirilen bu teknoloji, özellikle beyin, omurilik ve kas-iskelet sistemi gibi kompleks dokuların değerlendirilmesinde devrim

niteliğinde bir araç haline gelmiştir (Hashemi vd., 2012). MRI, üstün çözünürlük sunmasının yanı sıra iyonlaştırıcı radyasyon kullanmamasıyla da dikkat çeker. Bu özelliği, onu diğer görüntüleme yöntemlerinden ayıran temel avantajlardan biri olarak öne çıkarmaktadır (Yousaf vd., 2018). Bu yöntem, güçlü manyetik alanlar ve radyo dalgaları kullanarak yumuşak dokuların detaylı görüntülerini sağlar. T1 ağırlıklı görüntüler, anatomik detayların net bir şekilde görünmesini sağlar. Kontrast madde uygulamasıyla da tümör dokusunun çevre dokulardan daha belirgin bir şekilde ayrılmasına olanak tanınır (Xiao vd., 2016). T2 ağırlıklı görüntüler, ödem ve sıvı birikimi gibi patolojik değişiklikleri vurgular. Sıvıyla zayıflatılmış inversiyon kurtarma (FLAIR) görüntülemesi ise sıvı sinyalini baskılayarak ödem ve lezyonları daha ayrıntılı bir şekilde inceleme sağlamaktadır (Xiao vd., 2016; Yousaf vd., 2018). Gadolinyum bazlı kontrast maddeler, tümör sınırlarını ve vasküler yapıları net bir şekilde görüntüleyerek hastalığa yönelik önemli bilgiler sağlar (Xiao vd., 2016). Bu özellikleriyle MRI, beyin tümörlerinin tespitinde modern tıbbın en önemli araçlarından biri haline gelmiştir (Şekil 2.2.) (Xiao vd., 2016; Dale vd., 2015).




Şekil 2.2. Primer tümörlere ait MR görüntüleri a) Glioma MR görüntüsü b) Meningioma MR görüntüsü c) Pituitary MR görüntüsü (Rahmen vd., 2020)

MRI cihazı, genellikle 1.5 Tesla veya 3 Tesla gücünde bir manyetik alan oluşturarak vücuttaki hidrojen atomlarının manyetik momentlerini hizalar. Bu manyetik alan, hidrojen atomlarının protonlarının paralel ya da anti-paralel şekilde hizalanmasını sağlar. Bu düzenleme MRI görüntüleme sürecinin temel adımlarından biridir (Dale vd., 2015; Yousaf vd., 2018).

Radyo Frekansı (RF) darbeleri, MRI teknolojisinin temel unsurlarından biridir. RF dalgaları gönderilerek, protonların manyetik alana dik bir şekilde titreşmesi sağlanır ve bu durum protonların enerji kazanarak rezonans durumuna geçmesine neden olur (Dale vd., 2015). Güncel araştırmalar, özellikle ultra kısa eko zamanlı ve sıfır eko zamanlı MRI tekniklerinde RF darbeleri sırasında T2 gevşemesinin etkilerinin önemli bir faktör olduğunu vurgulamaktadır (Larson, 2016). MRI görüntüleme sürecinde, enerji yayılımı ve T1-T2 gevşeme süreçleri de kritik bir rol oynamaktadır. T1 gevşeme, protonların manyetik alana paralel hizalanma durumuna geri dönmesi sırasında yayılan enerjiyi ifade eder. T1 gevşeme süresi, farklı doku türlerine göre değişiklik gösterir ve MRI görüntülerinde kontrast oluşturmada önemli bir rol oynamaktadır. Ayrıca, T1 haritalama

yöntemlerinin doğruluğu ve verimliliği, manyetik rezonans parmak izi (MRPİ) teknikleriyle artırılabilir (Larson, 2016; Leitão vd., 2020). T2 gevşeme ise protonların birbirleriyle etkileşimi sonucu enerjilerini kaybederek sinyal kaybına yol açmasını ifade eder. Bu süreç, özellikle doku mikroyapısının karakterizasyonunda önemli bir yere sahiptir (Dale vd., 2015; Larson vd., 2016).



Şekil 2.3. MR görüntüleme sistemi çalışma mekanizması (Yüksel, 2019).

Protonlardan yayılan sinyaller, MRI bobinleri tarafından algılanır ve bu sinyaller, görüntüleme yazılımı aracılığıyla üç boyutlu görüntülere dönüştürülür (Şekil 2.3.) (Yüksel, 2019; Nielsen vd., 2018). Bu temel prensip, MRI teknolojisinin anatomik ve patolojik bilgilerin detaylı bir şekilde değerlendirilmesinde güçlü bir araç olmasını sağlar. MRI, çeşitli patolojik durumları değerlendirmek için farklı manyetik rezonans protokolleri ve ağırlıklarla çalışan, optimize edilmiş görüntüleme modlarına sahiptir (Doan vd., 2013) Bu modlar, tanı ve tedavi süreçlerinde kritik bilgiler sunar. T1 ağırlıklı görüntüleme, anatomik detayları net bir şekilde göstermesiyle öne çıkar. Beyaz madde ve gri madde ayırımında oldukça etkilidir. Ayrıca, kontrast madde (gadolinyum) kullanımıyla tümör vaskülaritesi ve sınırları daha belirgin hale getirilebilir, bu da özellikle tümör tanısı ve sınıflandırmasında büyük önem taşır (Xiao vd., 2016; Yüksel, 2019). T2 ağırlıklı görüntüleme, sıvı içeriği yüksek dokuları (örneğin ödem ve tümör içindeki sıvılar) parlak bir şekilde gösterir. Bu özelliği sayesinde beyindeki inflamasyon veya ödem varlığını tespit etmek için ideal bir yöntemdir. FLAIR görüntüleme, serbest sıvıyı baskılayarak tümörler ve ödemler arasındaki kontrastı artırır (Xiao vd., 2016). Difüzyon ağırlıklı görüntüleme, su moleküllerinin difüzyon hareketlerini ölçerek doku mikroyapısı hakkında bilgi sağlar. Akut iskemik inme ve yüksek dereceli malign tümörlerin tespitinde oldukça etkilidir (Holdsworth vd., 2008). Perfüzyon MRI, tümör vaskülaritesini ve kan akışını değerlendirerek yüksek dereceli gliom gibi tümörlerde malignite potansiyelini belirlemek için kullanılır. Bu özellik, tümörlerin biyolojik aktivitesini ve tedaviye yanıtını değerlendirmek açısından değerli bir yöntem sunar (van Dijken vd., 2019). Kontrastlı

MRI, malign tümörlerde artmış vaskülariteyi ve nekrotik alanları tespit ederek malignite derecesinin doğru bir şekilde değerlendirilmesine olanak tanır (Zhuang vd., 2022).

Cerrahi planlamada da önemli bir yere sahip olan MRI, cerrahların ameliyat sırasında detaylı anatomik bilgileri kullanarak kritik yapıların korunmasını sağlamasına yardımcı olur (Williams vd., 2020). Bunun yanı sıra, radyoterapi veya kemoterapi gibi tedavi süreçlerinin ardından tümör boyutundaki değişikliklerin izlenmesinde etkili bir araç olarak kullanılır (Zhuang vd., 2022). MRI, diğer görüntüleme yöntemlerine kıyasla birçok avantaj sunmaktadır. Beyin ve omurilik gibi karmaşık dokuları detaylı bir şekilde görüntüleyebilmesi, X-ışını ve BT taramalarına kıyasla iyonize radyasyon içermemesi nedeniyle daha güvenli bir seçenek olması ve farklı patolojiler için optimize edilebilen protokoller sunması, bu yöntemi ön plana çıkaran özellikler arasındadır (Yousaf vd., 2018; Dale vd., 2015). Bununla birlikte, MRI'nın güçlü yönlerine rağmen bazı sınırlamaları da bulunmaktadır. Yüksek maliyeti, metal implantlar veya kalp pili bulunan hastalarda kullanım kısıtlamaları ve uzun tarama sürelerine bağlı olarak oluşabilecek hareket artefaktları, bu yöntemin dezavantajları arasında yer alır (Turner, 2016; Patel vd., 2018).


Son yıllarda, MRI teknolojisinde kaydedilen ilerlemeler, bu yöntemin doğruluğunu artırmış ve kullanım alanlarını genişletmiştir. Özellikle derin öğrenme algoritmalarının kullanımı, MRI görüntülerinin otomatik segmentasyonu ve sınıflandırılmasında önemli bir yenilik sunmaktadır (Litjens vd., 2017; Turner, 2016). Bunun yanı sıra, 7 Tesla MRI gibi daha güçlü manyetik alanlar, görüntü çözünürlüğünü önemli ölçüde artırarak daha detaylı analizlere olanak tanımaktadır (Kraff vd., 2015). Ayrıca, paralel tarama teknolojileri, görüntüleme sürelerini kısaltarak hem hasta konforunu artırmış hem de klinik uygulamalarda zaman tasarrufu sağlamıştır (Patel vd., 2021).

2.3. Yapay Zeka

Yapay Zeka (YZ), makinelerin öğrenme, muhakeme yapma, problem çözme ve insan benzeri davranışlar sergileme yeteneklerini kazanmalarını sağlayan teknolojik bir alandır (Russell ve Norvig, 2021). İnsan zekasına benzer şekilde çalışan bu sistemler, bilgi işleme, öğrenme, adaptasyon ve karar verme gibi karmaşık süreçleri gerçekleştirecek şekilde tasarlanmıştır (Goodfellow vd., 2016). YZ'nin temel hedefi, insan zekasının belirli yönlerini modelleyerek gerçek dünya problemlerine etkili çözümler sunmaktır (LeCun vd., 2015). Derin öğrenme gibi YZ'nin alt dalları, sistemlerin büyük veri kümelerinden öğrenmesini ve karmaşık görevlerde üstün performans sergilemesini mümkün kılmaktadır (Şekil 2.4.) (Goodfellow vd., 2016). Özellikle sinir ağları ve makine öğrenimi teknikleri, YZ'nin öğrenme ve adaptasyon süreçlerini geliştirerek bu teknolojinin hızla evrimleşmesine katkı sağlamaktadır (LeCun vd., 2015).

Yapay zeka, hem felsefi hem de bilimsel temellere dayanan bir disiplin olarak, insanların makinelerin düşünebilme kapasitesini sorgulamasına yönelik ilgisinin antik çağlara kadar uzandığı köklü bir geçmişe sahiptir. Aristoteles'in mantık üzerine yaptığı çalışmalar, bu alanda atılmış ilk adımlardan biri olarak kabul edilmektedir (Russell ve Norvig, 2021). Modern yapay zekanın temelleri ise 20. yüzyılda Alan Turing'in

makinelerin düşünme kapasitesini değerlendiren öncü çalışmalarıyla atılmıştır (Moor, 2001). 1956 yılında düzenlenen Dartmouth Konferansı'nda "yapay zeka" teriminin ilk kez ortaya atılmasıyla, belirli görevleri yerine getirebilen algoritmaların geliştirilmesine yönelik sistematik çalışmalar başlamıştır (McCarthy vd., 2006). Ancak, 1970'ler ve 1980'lerde sınırlı donanım kapasitesi ve yüksek maliyetler nedeniyle yapay zeka araştırmaları bir duraklama dönemi yaşamıştır. Bu dönem, 1990'ların sonlarında artan hesaplama gücü ve yeni teknolojik gelişmelerle sona ermiş; makine öğrenmesi ve uzman sistemler gibi alt alanlar yeniden ön plana çıkmıştır (Nilsson, 2009). 2010'lu yıllarda derin öğrenme algoritmalarının büyük veri teknolojileriyle entegrasyonu, yapay zekanın performansını zirveye taşımış ve bu teknolojiyi hemen her sektörde kullanılabilir hale getirmiştir (Goodfellow vd., 2016).



Şekil 2.4. Derin öğrenme, makine öğrenmesi ve yapay zeka arasındaki hiyerarşik yapı (Süslü, 2019)

2.3.1. Veri Kaynakları

Manuel veri toplama, bireylerin doğrudan veri girişi yaptığı ve işlemleri elle gerçekleştirdiği bir yöntemdir. Bu süreçte, veriler genellikle manuel olarak işlenir veya kategorilere ayrılır. Örneğin, bir görüntü veri setinin elle etiketlenmesi ya da bir anketin yanıtlarının bir veri tablosuna manuel olarak aktarılması, bu yöntemin sık rastlanan uygulamalarıdır. Manuel veri toplamanın en büyük avantajı, toplanan verinin yüksek doğruluk ve kontrol altında işlenebilmesidir; çünkü insanlar veriye bağlam üzerinden değerlendirme yaparak müdahale edebilirler (Zha, 2023). Ancak bu yöntem, büyük veri setleri söz konusu olduğunda zaman alıcı ve maliyetli bir hale gelir. Ayrıca, insan hatası ve önyargıya açık olması, verinin doğruluğunu olumsuz yönde etkileyebilir (Biemer &

Lyberg, 2003). Bu nedenle, manuel veri toplama genellikle küçük veri setlerinde tercih edilmekte ve büyük veri setlerinde otomatik yöntemlerle desteklenmesi önerilmektedir.

Otomatik veri toplama, algoritmalar, yazılımlar veya sensörler aracılığıyla veri elde edilmesini sağlayan bir yöntemdir. Genellikle büyük ölçekli veri ihtiyaçlarını karşılamak için tercih edilir ve manuel yöntemlere göre çok daha hızlı ve verimli bir süreç sunar. Örneğin, web scraping teknikleri kullanılarak bir web sitesinden veri çekmek veya sosyal medya API'leri (Uygulama Programlama Arayüzü) aracılığıyla kullanıcı gönderilerinin toplanması, otomatik veri toplama yöntemlerine örnek olarak gösterilebilir (Whang vd., 2023). Bu yöntem, büyük miktarda veriyi hızlı bir şekilde toplamak için uygundur ve sürekli bir veri akışı sağlayabilir. Ancak, bu veriler genellikle ham formatta olduğu için temizlenmesi ve işlenmesi gereklidir (Marr, 2021). Bunun yanı sıra, otomatik veri toplama süreçlerinde yasal düzenlemeler ve etik ilkeler büyük önem taşır. Özellikle, veri gizliliği ve kullanıcı haklarına ilişkin konuların titizlikle ele alınması gerekir (Whang vd., 2023). Otomatik veri toplamanın bu avantajları ve sınırlamaları, veri biliminde yaygın olarak kullanılan bir yöntem olmasını sağlamaktadır.

Hazır veri setleri, açık kaynak platformlar, üniversiteler veya ticari sağlayıcılar tarafından sunulan, önceden yapılandırılmış ve genellikle etiketlenmiş veri kümeleridir. Kaggle, UCI Machine Learning Repository, ImageNet ve OpenML gibi platformlar, eğitim ve araştırma amaçlarıyla sıklıkla tercih edilen popüler veri setlerini kullanıcıların erişimine açmaktadır (Deng vd., 2009). Bu tür veri kaynaklarının en büyük avantajı, genellikle temizlenmiş, düzenlenmiş ve doğrudan kullanıma hazır olmalarıdır. Hazır veri setleri, araştırma süreçlerini hızlandırır ve algoritmaların eğitimi için sağlam bir temel oluşturur. Ancak, bu veri setlerinin kullanımında dikkat edilmesi gereken bazı sınırlılıklar bulunmaktadır. Çoğu hazır veri seti, laboratuvar ortamında veya kontrollü koşullarda oluşturulduğundan, gerçek dünya problemlerini tam olarak yansıtmayabilir (Torralla ve Efron, 2011). Bu durum, özellikle uygulama alanının bağlamına özel veriler gerektiğinde, hazır veri setlerinin yetersiz kalmasına neden olabilir. Ayrıca, bu veri setlerinin projeye özgü gereksinimleri karşılaması için ek işlem veya yeniden yapılandırma gerekebilir. Dolayısıyla hazır veri setlerini kullanırken, verinin niteliği, bağlamı ve sınırlılıkları dikkatle değerlendirilmelidir (Whang vd., 2023).

2.3.2. Veri Toplama Teknikleri

Makine öğrenmesi projelerinde kullanılacak veriler, çeşitli teknikler kullanılarak toplanabilir. Bu teknikler, veri kaynağına, veri türüne ve projenin gereksinimlerine bağlı olarak farklılık gösterir. Her veri toplama yöntemi, kendine özgü avantajlar ve zorluklar içerir ve projeye uygun yöntem seçimi, başarılı bir veri işleme sürecinin temelini oluşturur. Aşağıda, farklı veri toplama yöntemleri detaylı bir şekilde incelenmiştir.

Sensörlerden veri toplama, fiziksel cihazlar aracılığıyla çevresel veya durumsal bilgilerin elde edilmesini sağlayan bir yöntemdir. Özellikle Nesnelerin İnterneti (IoT) cihazlarının yaygınlaşmasıyla bu teknik, veri toplama süreçlerinde önemli bir yer

edinmiştir. Sensörlerden elde edilen veriler, sıcaklık, nem, basınç ve hız gibi parametreleri içerebilir. Örneğin, bir akıllı ev sisteminde sıcaklık sensörleri, ev içindeki sıcaklığı sürekli ölçerek enerji yönetimini optimize etmek için kullanılabilir. Bu yöntem, fiziksel dünyadan doğrudan veri toplama avantajı sağlarken, toplanan verilerin genellikle ham formatta olması nedeniyle analiz öncesinde temizlenmesi ve işlenmesi gereklidir (Gubbi vd., 2013). Sensör verilerinin makine öğrenmesi ve büyük veri analizine entegrasyonu; enerji yönetimi, çevresel analiz ve endüstriyel otomasyon gibi alanlarda yaygın bir şekilde uygulanmaktadır.

Web scraping, internet sitelerinden veri toplamak için kullanılan bir yöntemdir. BeautifulSoup ve Scrapy gibi araçlar aracılığıyla uygulanan bu teknik, haber makaleleri, ürün bilgileri veya sosyal medya içeriklerini toplamak için sıklıkla tercih edilir (Mitchell, 2018). Örneğin, bir haber analiz projesinde, belirli anahtar kelimelerle ilişkili haber makaleleri ve başlıklar toplanabilir. Web scraping'in en büyük avantajlarından biri, geniş miktarda veriye hızlı erişim sağlamasıdır. Ancak, dinamik web yapıları, telif hakkı ve veri gizliliği gibi etik ve yasal sorunlar bu yöntemin kullanımında dikkat edilmesi gereken başlıca unsurlardır (Krotov vd., 2020). Ayrıca, çekilen verilerin anlamlı hale gelmesi için yapılandırma ve temizleme işlemleri gereklidir.

Uygulama Programlama Arayüzü (API), belirli bir sistemle etkileşim kurarak yapılandırılmış veri çekme ve gönderme olanağı sunar (Glez-Peña vd., 2014). Örneğin, Twitter API kullanılarak belirli bir hashtag ile ilişkili tweet'ler toplanabilir veya Google Maps API ile bir bölgedeki işletmelerin konum bilgileri elde edilebilir. API'ler, genellikle iyi dokümanite edilmiş ve yapılandırılmış veri sağlamaları nedeniyle büyük bir avantaj sunar (Zhang vd., 2019). Bununla birlikte, API kullanımı genellikle kota sınırlamaları, erişim politikaları ve ücretlendirme gibi kısıtlamalarla sınırlandırılabilir. Bu nedenle, API'lerin kullanımında bu faktörlerin dikkate alınması önemlidir.

Deneyisel veri, kontrollü ortamlarda veya laboratuvar deneyleri sırasında toplanan veri türüdür. Özellikle tıbbi araştırmalarda sıkça kullanılan bu yöntem, MR ve röntgen gibi görüntüleme cihazlarından elde edilen veriler için tercih edilmektedir (Louis vd., 2016). Deneyisel veriler, genellikle belirli bir problemi çözmek veya bir hipotezi test etmek için özel olarak tasarlandığından oldukça değerlidir. Ancak bu veriler, genellikle yüksek maliyetli olup özel ekipman ve deney ortamı gerektirdiği için zaman alıcı olabilir. Ayrıca, deneyisel verilerin güvenilirliği, deney tasarımı ve uygulama sürecinin doğruluğuna doğrudan bağlıdır (Mandel, 2012).

Veri toplama ve işleme süreçleri, çeşitli zorluklarla karşılaşılabilen karmaşık bir süreçtir. Bu zorluklardan biri, veri kalitesidir. Toplanan veriler eksik, hatalı veya gereksiz bilgiler içerebilir. Bu durum, analiz ve modelleme süreçlerini olumsuz etkileyerek sonuçların doğruluğunu azaltabilir. Örneğin, bir müşteri veri tabanında eksik e-posta adresleri veya yanlış yaş bilgileri bulunması, analizlerin güvenilirliğini düşürebilir. Bu tür sorunların üstesinden gelmek için eksik değerlerin doldurulması, hatalı verilerin

düzeltilmesi ve gereksiz bilgilerin ayıklanması gibi veri temizleme teknikleri uygulanmaktadır (Kotsiantis vd., 2006).

Bir diğer önemli zorluk, veri boyutudur. Büyük ölçekli veri setleri, depolama ve işleme süreçlerinde ciddi performans sorunlarına yol açabilir. Örneğin, milyarlarca kayıt içeren bir veri tabanının işlenmesi büyük miktarda depolama alanı ve yüksek işlem gücü gerektirir. Bu sorunu aşmak için örnekleme veya boyut azaltma teknikleri kullanılabilir. Bu yöntemler, analiz sürecini hızlandırırken donanım kaynaklarının daha verimli kullanılmasını sağlar (Han vd., 2011).

Veri etiketlemede de önemli bir zorluk olarak öne çıkar. Etiketleme işlemi genellikle manuel olarak yapıldığından zaman alıcı ve maliyetli bir süreçtir. Örneğin, bir görüntü veri setinde her bir görselin kategoriye göre sınıflandırılması manuel etiketleme gerektirebilir. Bu zorluğu aşmak için otomatik etiketleme algoritmaları veya kitle kaynak kullanımı yöntemleri kullanılabilir. Kitle kaynak kullanımı yöntemi, geniş bir insan topluluğunu etiketleme sürecine dahil ederek zaman ve maliyet avantajı sağlar (Hemetsberger, 2013).


Son olarak, veri gizliliği ve güvenlik, özellikle kişisel verilerin kullanımı söz konusu olduğunda kritik bir endişe kaynağıdır. Kişisel veriler, yasal düzenlemeler ve etik standartlar çerçevesinde korunmalıdır. Örneğin, sağlık verilerinin analizinde hastaların kimlik bilgilerinin gizliliği büyük önem taşır. Bu tür sorunların çözümünde anonimleştirme ve şifreleme yöntemleri uygulanabilir. Anonimleştirme, kişisel bilgileri kaldırarak veriyi güvenli hale getirirken, şifreleme, veriyi yetkisiz erişimlere karşı korur (Narayanan & Shmatikov, 2008).

2.3.3. Makine Öğrenmesi

Makine Öğrenmesi (ML), bilgisayarların açık bir şekilde programlanmadan, verilerden öğrenerek karar verme veya tahmin yapma yeteneği kazandığı bir yapay zeka alt alanıdır (Goodfellow vd., 2016). Bu teknoloji, matematiksel modeller ve istatistiksel yöntemler kullanarak sistemlerin performansını artırmayı hedefler. Geleneksel programlamadan farklı olarak, ML algoritmaları manuel talimatlar yerine veri ve deneyimlerden öğrenir (Murphy, 2022).

Makine öğrenmesinin temelleri, 1952'de Arthur Samuel'in dama oyunu için geliştirdiği ilk öğrenme algoritmasıyla atılmıştır. 1960'larda perceptron modeli, yapay sinir ağlarının başlangıcını oluşturmuş ve bu alanda önemli bir dönüm noktası olmuştur (LeCun vd., 2015). 1980'lerde geri yayılım (backpropagation) algoritmasının geliştirilmesi, sinir ağlarının eğitimi kolaylaştırarak modern derin öğrenme yöntemlerinin önünü açmıştır. 1990'lardan itibaren büyük veri teknolojilerinin gelişimi ve artan hesaplama gücü, makine öğrenmesinin sağlık, finans ve üretim gibi birçok sektörde yaygın bir şekilde uygulanmasını sağlamıştır (Schmidhuber, 2015; Chollet,

2021). Bu gelişmeler, makine öğrenmesini günümüzdeki geniş uygulama alanlarına ulaştırmış ve hem bilimsel hem de endüstriyel ilerlemelerde kritik bir rol üstlenmesini mümkün kılmıştır. Makine öğrenmesi çalışma algoritmalarına göre üç dala ayrılmıştır. Bu yöntemler; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak sınıflandırılmaktadır (Şekil 2.5.).



Şekil 2.5. Makine öğrenmesi alt dalları

Denetimli öğrenme, girdi verileri ile bu verilere karşılık gelen doğru çıktı değerlerinin bulunduğu etiketli bir veri seti üzerinde çalışan bir makine öğrenmesi yöntemidir (Şekil 2.6.) (Zhou, 2021). Bu yöntemde model, verilen giriş verilerinden doğru çıktıyı tahmin etmeyi sağlayan bir fonksiyon öğrenmektedir. Denetimli öğrenmenin temel amacı, eğitim sürecinde hata oranını minimize ederek modelin doğru tahminlerde bulunma kapasitesini artırmaktır. Bu süreçte, modelin tahmin ettiği sonuçlar gerçek etiketlerle karşılaştırılır ve model, oluşan hataları minimize etmek için optimize edilmektedir (El Naqa vd., 2015)


Denetimli öğrenme, iki ana kategoriye ayrılır:

Sınıflandırma: Verilerin belirli kategorilere veya sınıflara ayrıldığı bir problem türüdür. Örneğin, bir e-postanın “spam” ya da “spam değil” olarak sınıflandırılır (Jordan and Mitchell, 2015).

Regresyon: Sürekli bir değişkenin tahmin edilmesini hedefleyen bir problem türüdür. Örneğin, bir evin fiyatının tahmin edilmesini sağlamaktadır (El Naqa vd., 2015)

Örnek Algoritmalar:

- Lojistik regresyon
- Destek vektör makineleri
- Yapay sinir ağları



Şekil 2.6. Denetimli öğrenme çalışma mekanizması

Denetimsiz öğrenme, etiketlenmemiş veri setleri üzerinde çalışarak verideki gizli yapıların keşfedilmesine odaklanan bir makine öğrenmesi yöntemidir (Şekil 2.7.) (Hahne vd., 2008; Zhou, 2021). Bu yöntem, çıktıya dair bir etikete sahip olmayan verilerle çalışır ve model, yalnızca giriş verilerinin özelliklerini analiz ederek gruplama veya boyut indirgeme gibi işlemleri gerçekleştirmektedir (Shinde vd., 2018). Denetimsiz öğrenme, genellikle veri keşfi, öznelik mühendisliği ve veri özetleme gibi amaçlarla kullanılmaktadır.

Kümeleme: Verileri benzer özelliklere göre gruplandırmayı amaçlamaktadır. Örneğin, müşteri segmentasyonu yaparak benzer davranışlara sahip müşteri gruplarını belirlemektedir (Mahesh, 2020).

Boyut İndirgeme: Yüksek boyutlu verileri daha az boyutla temsil etmeyi hedeflemektedir. Bu, hem veri analizi hem de görselleştirme süreçlerini kolaylaştırmaktadır. Örneğin, Temel Bileşen Analizi, veri setindeki en anlamlı değişkenleri koruyarak boyutu azaltan bir yöntemdir. Denetimsiz öğrenme modelleri, çıktı etiketi olmayan veri setleri üzerinde çalışabilir. Model, veriler arasındaki doğal bağlantıları ve örüntüleri belirlemeye odaklanmaktadır. Denetimsiz öğrenme, analiz öncesinde veri setinin daha iyi anlaşılmasını sağlamaktadır (Hahne vd., 2008).

Örnek Algoritmalar:

- K-Ortalamlar:** Verileri belirli bir sayıda kümeye ayırır ve her küme, merkezi bir nokta (centroid) etrafında tanımlanır.

- Hiyerarşik Kümeleme:** Verileri hiyerarşik bir yapı içinde gruplandırır ve dendrogram adı verilen bir ağaç yapısı oluşturmaktadır.


- t-Dağıtılmış Stokastik Komşu Gömme:** Yüksek boyutlu verileri düşük boyutlu bir alana indirerek görselleştirme amacıyla kullanmaktadır (Naeem vd., 2023).



Şekil 2.7. Denetimsiz öğrenme çalışma mekanizması

Pekiştirmeli öğrenme, bir ajanın bulunduğu ortamda nasıl hareket edeceğini deneyimleyerek öğrenmesine odaklanan bir makine öğrenmesi yöntemidir (Şekil 2.8.). Bu süreçte ajan, bir durumdayken bir eylem gerçekleştirir ve bu eylemin sonucunda ödüllendirilir ya da cezalandırılır (Kulkarni, 2012). Amaç, uzun vadede en yüksek toplam ödülü elde etmek için en iyi eylem stratejisini, yani politikayı öğrenmektir.

Pekiştirmeli öğrenme sürecinde, temel kavramlar ve bileşenler ajanın (agent) öğrenme, karar verme mekanizmasını şekillendirir. Ajan, bir ortamda hareket eden ve belirli durumlara göre kararlar veren öğrenme mekanizmasıdır; örneğin, bir oyunu oynayan yapay zeka bir ajan olarak düşünülebilir (Schwart, 2014). Ajanın içinde bulunduğu ortam, onun eylemlerinin sonuçlarını belirleyen bir sistemdir. Bu ortam, bir labirent oyunu gibi somut bir yapı olabilir. Durum ise ortamın her bir anındaki mevcut konumunu ifade eder; örneğin, bir robotun anlık olarak bulunduğu yer ortamın durumu olarak tanımlanabilir (Fayaz vd., 2022).




Şekil 2.8. Pekiştirmeli öğrenme çalışma mekanizması

Ajan, her durumda bir eylem gerçekleştirmektedir. Bu eylem, mevcut durumdaki bir hamleyi veya kararı temsil etmektedir; örneğin, bir adım ileri gitmek gibi. Eylemlerin sonuçları, ödül kavramı ile ölçülmektedir (Ghavamzadeh vd., 2015). Ödül, ajan tarafından alınan geri bildirimi ifade etmektedir; pozitif ödüller istenen davranışları teşvik ederken, negatif ödüller (veya cezalar) istenmeyen davranışları caydırmaktadır. Ajanın bu süreçteki karar mekanizması, politika ile şekillenmektedir. Politika, ajanın her durumda hangi eylemi seçeceğini belirleyen stratejidir (Barto, 2021). Bunun yanı sıra, değer fonksiyonu her durumun ya da durum-eylem çiftinin gelecekteki ödüller açısından ne kadar değerli olduğunu tahmin ederek ajanın uzun vadeli hedeflerine ulaşmasında kritik bir rol oynamaktadır (Ghavamzadeh vd., 2015). Bu temel bileşenler, pekiştirmeli öğrenmenin dinamik yapısını oluşturarak ajanın çevresine uyum sağlamasını ve öğrenmesini mümkün kılmaktadır.

Q-Öğrenme, tablo tabanlı bir pekiştirmeli öğrenme algoritmasıdır. Bu yöntem, her durum-eylem çiftine bir değer atayan bir “Q-tablosu” oluşturmaktadır. Ajan, bu tabloyu kullanarak hangi eylemin en yüksek ödülü getireceğini öğrenmektedir. Her eylem sonucunda Q-tablosu güncellenmekte ve ajan, uzun vadede en iyi ödüllerini sağlayacak bir politika geliştirmektedir (Barto, 2021). Q-öğrenme, basit ve anlaşılır bir yapıya sahiptir ve küçük ortamlar için oldukça etkilidir. Ancak, durum ve eylem uzayı büyüdüğünde verimliliği düşer, bu da yöntemi büyük ölçekli problemler için daha az uygun hale getirmektedir (Fayaz vd., 2022).

Derin Q-Ağları (DQA), derin öğrenme ile Q-öğrenme algoritmasını birleştiren bir yaklaşımdır. Geleneksel Q-öğrenme’de kullanılan tablo yerine, bir sinir ağı kullanarak durum-eylem çiftlerinin Q değerlerini tahmin etmektedir (Şekil 2.9.) (Mousavi vd., 2018). Bu yöntem, özellikle durum uzayının çok büyük olduğu senaryolarda (örneğin, video oyunları gibi yüksek boyutlu problemler) Q-öğrenme’in sınırlamalarını aşmak için geliştirilmiştir. DQA, karmaşık ortamlar ve büyük durum uzaylarında etkili bir şekilde çalışabilmektedir (Dong vd., 2020). Bu özelliği, özellikle büyük veri kümeleri ve geniş arama alanları içeren problemlerde tercih edilmesini sağlamaktadır. Ancak, DQA’nin eğitim süreci oldukça uzun olabilir ve yüksek hesaplama gücü gerektirmektedir. Bu durum, özellikle sınırlı kaynaklara sahip sistemlerde uygulanabilirliğini zorlaştırmaktadır (Wang vd., 2022).



Şekil 2.9. Derin Q- Öğrenme çalışma prensibi

Politika Gradyan Yöntemleri, ajanların doğrudan bir politikayı öğrenerek bu politikayı sürekli optimize ettiği bir pekiştirmeli öğrenme yaklaşımıdır. Politika, bir durum için hangi eylemin yapılacağını olasılıksal olarak belirler (Wang vd., 2022). Bu yöntem, özellikle sürekli aksiyon uzaylarında ve karmaşık kontrol problemlerinde etkili bir şekilde kullanılabilir. Örneğin, bir robotun kollarını hareket ettirerek bir nesneyi alması gibi senaryolarda Politika Gradyan Yöntemleri sıkça tercih edilmektedir (Dong vd., 2020). Bu yöntem, sürekli aksiyon uzaylarında çalışabilmesi sayesinde geleneksel pekiştirmeli öğrenme yöntemlerinin uygulanmasının zor olduğu problemlerde üstün performans sergilemektedir. Ancak öğrenim süreci kararsız olabilir ve optimizasyon süreçleri daha karmaşık hale gelebilmektedir. Bu durum, eğitim sırasında daha fazla dikkat ve hesaplama gücü gerektirmektedir (Wang vd., 2022).

2.3.3.1. Makine Öğrenmesinin Çalışma Mekanizması

Model performansı, veri toplama sürecinin doğrudan şekillendirdiği en önemli unsurlardan biridir. Modelin doğru tahminler yapabilmesi ve genelleme yeteneğinin yüksek olması, sağlanan verilerin kalitesine ve miktarına bağlıdır. Eğitim sürecinde, model, topladığı bu verilerden öğrenerek yeni ve bilinmeyen veri üzerinde güçlü bir performans sergileyebilmektedir. Örneğin, yüz tanıma sistemlerinde, farklı açılardan çekilmiş, net ve yeterli sayıda yüz görüntüsü sağlandığında, modelin doğruluk oranı ve genelleme kapasitesi önemli ölçüde artmaktadır. Buna karşılık, eksik, hatalı veya tutarsız veriler, modelin öğrenme sürecini olumsuz etkileyerek tahminlerinde sapmalara neden olabilmektedir (Han vd., 2011). Bu nedenle, veri toplama sürecinde dikkatli ve sistematik bir yaklaşım benimsemek kritik öneme sahiptir. Verilerin temiz, tutarlı ve yeterli miktarda olması, yalnızca modelin doğruluğunu artırmakla kalmaz, aynı zamanda genelleme yeteneğini de güçlendirmektedir (Shorten & Khoshgoftaar, 2019). Veri kalitesindeki herhangi bir eksiklik, model performansını olumsuz yönde etkileyebileceği için, veri toplama ve hazırlık aşamalarına özen göstermek gereklidir.

Genelleme yeteneği, bir modelin, eğitim sırasında görmediği yeni veriler üzerinde iyi performans gösterebilme kapasitesini ifade eder. Bu yetenek, farklı kaynaklardan toplanan çeşitli veri türleriyle önemli ölçüde artırılabilir. Çeşitli veri türleri ve örüntüleri içeren bir veri seti, modelin daha geniş bir veri kümesini öğrenmesine olanak tanımakta ve böylece model, gerçek dünya senaryolarında daha başarılı olmaktadır. Örneğin, bir dil modeli yalnızca belirli bir bölgeden toplanan metinlerle eğitildiğinde, başka bölgelerden gelen verileri anlamakta zorlanabilir. Ancak farklı bölgelerden, kültürlerden ve dillerden gelen metinlerle eğitilen bir model, çok daha güçlü bir genelleme yeteneği kazanmaktadır (Goodfellow vd., 2016). Çeşitliliği artırılmış veri setleri, yalnızca genelleme yeteneğini geliştirmekle kalmaz, aynı zamanda modelin gerçek dünya uygulamalarındaki güvenilirliğini de artırmaktadır (Zhang vd., 2021).

Aşırı öğrenme, veri toplama ve model geliştirme süreçlerinde sıklıkla karşılaşılan bir problemdir. Bu sorun, modelin yalnızca eğitim verilerine aşırı uyum göstermesi ve bu nedenle yeni veriler üzerinde zayıf bir performans sergilemesiyle karakterizedir. Örneğin, bir ürün öneri sistemi, yalnızca birkaç kullanıcıdan alınan verilerle eğitildiğinde, model bu kullanıcıların tercihlerini ezberler. Ancak, farklı kullanıcı gruplarının davranışlarını genellemekte zorlanır ve bu da modelin gerçek dünya performansını olumsuz etkilemektedir (Goodfellow vd., 2016). Aşırı öğrenmeyi önlemek için veri setinin yeterli boyutta ve çeşitlilikte olması kritik bir öneme sahiptir. Eğitim sürecinde kullanılan veri artırma teknikleri, rastgele gürültü ekleme, düzenlileştirici yöntemler ve çapraz doğrulama stratejileri, bu sorunun çözümünde etkili araçlar olarak öne çıkmaktadır (Shorten & Khoshgoftaar, 2019). Bu yaklaşımlar, modelin daha geniş bir veri yelpazesine uyum sağlamasını destekleyerek genelleme yeteneğini artırır ve aşırı öğrenme riskini azaltmaktadır.

Veri ön işleme, makine öğrenmesi projelerinde ham verilerin temizlenmesi, dönüştürülmesi ve modele uygun hale getirilmesi sürecini ifade etmektedir. Bu adım, modelin verilerden etkili bir şekilde öğrenebilmesi için kritik bir role sahiptir (Wang vd., 2022). Toplanan veriler genellikle eksik bilgiler, hatalı girişler ve tutarsızlıklar içermektedir. Bu durum, modelin doğruluğunu ve genelleme yeteneğini olumsuz etkileyebilir. Bu nedenle, veri ön işleme sürecinde eksik değerlerin doldurulması, anormal verilerin düzeltilmesi ve verilerin standart bir formata dönüştürülmesi gibi işlemler gerçekleştirilir (Han vd., 2011). Bunun yanı sıra, ölçekleme ve normalizasyon gibi teknikler, modelin farklı veri türleriyle daha etkili çalışmasını sağlamaktadır. Örneğin, kategorik verilerin sayısal formata dönüştürülmesi, makine öğrenmesi algoritmalarının bu verileri daha iyi anlayabilmesine olanak tanımaktadır (Géron, 2022). Veri ön işleme, yalnızca modelin performansını artırmakla kalmaz; aynı zamanda, modelin gerçek dünya koşullarında güvenilir sonuçlar üretmesine ve genelleme yeteneğini geliştirmesine de katkıda bulunmaktadır.

Eksik Veri Tamamlama, veri ön işlemenin temel adımlarından biridir ve veri kalitesini artırarak model performansını optimize etmede önemlidir. Eksik veriler, analiz

ve modelleme süreçlerinde yanlış sonuçlara veya düşük doğruluk oranlarına yol açabilir. Örneğin, bir müşteri veritabanında bazı kullanıcıların yaş bilgisi eksik olduğunda, bu durum analizlerin güvenilirliğini olumsuz etkileyebilir (Wang vd., 2022). Eksik değerlerin tamamlanmasında çeşitli yöntemler kullanılabilir. Ortalama veya medyan gibi merkezi eğilim ölçütleriyle doldurma, sık kullanılan basit yaklaşımlardır. Daha karmaşık bir yöntem olarak, eksik değerlerin k-En Yakın Komşular algoritması gibi tahmin modelleriyle doldurulması tercih edilebilir (García-Laencina vd., 2010). Alternatif olarak, eksik veriye sahip kayıtların tamamen kaldırılması seçeneği de uygulanabilir. Ancak, bu yöntem, özellikle az veriyle çalışılan durumlarda değerli bilgilerin kaybına yol açabileceği için dikkatle değerlendirilmelidir (Enders, 2022).

Normalizasyon, veri özelliklerini aynı ölçeğe getirerek modelin öğrenme sürecinde dengeli bir yaklaşım sağlamasına yardımcı olmaktadır. Farklı ölçeklerdeki değerler, modelin özellikler arasında yanlış önceliklendirme yapmasına neden olabilir ve bu durum, öğrenme performansını olumsuz etkilemektedir. Örneğin, bir veri setinde maaş bilgileri milyonlar seviyesindeyken, yaş bilgileri 20-70 arasında değişiyorsa, model maaş bilgisini daha önemli bir özellik olarak kabul edebilir (Han vd., 2011). Normalizasyon, bu tür farklılıkları ortadan kaldırarak verileri belirli bir aralığa (örneğin 0 ile 1 arasında) dönüştürür ve tüm özelliklerin modele eşit katkıda bulunmasını sağlamaktadır. Bu işlem, özellikle gradient descent gibi optimizasyon yöntemleriyle çalışan modellerde öğrenme hızını artırır ve eğitim sürecindeki sapmaları azaltmaktadır (Seger, 2018).

Kodlama, kategorik verilerin sayısal formatlara dönüştürülmesi sürecidir ve makine öğrenmesi algoritmalarının bu verileri işleyebilmesi için kritik bir adımdır. Çoğu makine öğrenmesi algoritması, metinsel verileri doğrudan işleyemez ve yalnızca sayısal verilerle çalışabilir. Örneğin, bir veri setinde “cinsiyet” sütunu “erkek” ve “kadın” gibi metin değerleri içeriyorsa, bu değerlerin sayısal bir biçimde ifade edilmesi gerekir. Bu işlem için en yaygın kullanılan yöntemlerden biri tek sıcak kodlama (one-hot encoding)’dır (Seger, 2018). Tek sıcak kodlama, her bir kategoriye ayrı bir sütuna ayrılarak 0 ve 1 değerleriyle temsil etmektedir. Örneğin, “erkek” ve “kadın” kategorileri için iki sütun oluşturulur; “erkek” için [1, 0], “kadın” için [0, 1] şeklinde bir kodlama yapılır (Al-Shehari vd., 2021). Alternatif olarak, kategorik veriler arasında sıralı bir ilişki olduğunda etiket kodlama (label encoding) kullanılabilir. Bu yöntem, her kategoriye belirli bir sayısal değer atayarak daha basit bir dönüşüm sağlamaktadır. Ancak, sıralı ilişki bulunmayan kategorilerde bu yöntem, yanlış anlamalar veya model performansında düşüşe yol açmaktadır (Seger, 2018).

Makine öğrenmesi projelerinde doğru model seçimi, bir projenin başarısını doğrudan etkileyen en kritik adımlardan biridir. Model seçimi süreci, problemin türü, veri yapısının özellikleri, performans gereksinimleri ve hesaplama kapasitesi gibi faktörlere bağlıdır. Uygun algoritmaların seçimi, bu faktörlerin dikkate alınarak sistematik bir şekilde değerlendirilmesini ve performans metrikleri üzerinden karşılaştırılmasını gerektirir (Shalev-Shwartz & Ben-David, 2014). Problemin doğası, kullanılacak model

türünü belirlemede temel bir rol oynamaktadır. Sürekli değişkenlerin tahmini için regresyon algoritmaları uygunken, sınıflandırma problemlerinde lojistik regresyon, destek vektör makineleri veya karar ağaçları gibi yöntemler tercih edilmektedir. Örneğin, bir evin fiyatını tahmin etmeyi amaçlayan bir projede doğrusal regresyon modeli etkili bir çözüm sunarken, spam e-posta tespiti gibi sınıflandırma problemleri için rastgele orman (Random Forest) veya destek vektör makineleri kullanılabilir (Kuhn & Johnson, 2013). Veri setinin boyutu, dengesi ve türü, model performansını etkileyen önemli faktörlerdir. Büyük veri setleri için ölçeklenebilir ve hızlı işlem yapabilen algoritmalar tercih edilirken, küçük ve karmaşık veri setlerinde detaylı analiz yapabilen modeller, özellikle yapay sinir ağları, daha uygun bir çözüm olabilir. Örneğin, sosyal medya kullanıcılarının davranışlarını analiz eden projelerde büyük veri setlerine uyumlu modeller kullanılırken, tıbbi verilerin analizinde karmaşık yapılar nedeniyle derin öğrenme modellerine ihtiyaç duyulabilir (Goodfellow vd., 2016). Doğru model seçimini garanti altına almak için farklı modeller, doğruluk ve genelleme yetenekleri açısından karşılaştırılmalıdır. Çapraz doğrulama teknikleri, modellerin farklı veri alt kümelerinde test edilmesini sağlayarak seçim sürecini daha güvenilir hale getirmektedir. Böyle bir yaklaşım, yalnızca model performansını değil, aynı zamanda modelin gerçek dünya koşullarında nasıl çalışacağını da değerlendirme imkanı sunmaktadır (Bishop, 2006). Doğru model seçimi, makine öğrenmesi projelerinin başarısını belirleyen temel bir süreçtir. Yanlış bir model seçimi, düşük doğruluk, yüksek işlem süreleri veya modele uyumsuzluk gibi sorunlara yol açabilir. Bu nedenle, model seçimi sırasında problemin doğasına uygun sistematik bir yaklaşım benimsemek ve detaylı analizler yapmak gereklidir (Han vd., 2011).

Model eğitimi, makine öğrenmesi ve derin öğrenme projelerinin en kritik süreçlerinden biridir. Bu süreçte model, eğitim verilerindeki giriş ve çıkışlar arasındaki ilişkileri öğrenerek gelecekteki tahminlerinin doğruluğunu artırmayı hedeflemektedir. Model eğitimi, verilerin işlenmesi, tahminlerin yapılması ve parametrelerin optimize edilmesi gibi bir dizi matematiksel işlemi içermektedir. Bu adımlar, modelin performansını doğrudan etkilediği için dikkatle planlanması gerekir (Géron, 2019). Eğitim sürecinin ilk aşaması olan ileri yayılım, modelin mevcut parametrelerini kullanarak tahmin yapmasını sağlamaktadır. Bu adımda, giriş verileri modelin ağırlıkları ve katmanları boyunca ilerletilir ve bir çıktı üretilmektedir. Örneğin, bir görüntü sınıflandırma modeline bir resim verildiğinde, model bu resmin hangi kategoriye ait olduğunu tahmin eder (Shinde vd., 2018). Giriş verilerinin aktivasyon fonksiyonlarından geçirilmesiyle üretilen bu çıktı, modelin mevcut ağırlıklarının ne kadar doğru olduğunu değerlendirmek için kritik bir rol oynamaktadır (Aggarwal vd., 2020). Modelin tahmini, gerçek etiketle karşılaştırılarak hata miktarı belirlenir. Bu hata, kayıp fonksiyonları (loss functions) aracılığıyla ölçülmektedir. Kayıp fonksiyonları, modelin tahmin doğruluğunu değerlendirmenin yanı sıra, parametrelerin optimize edilmesinde de önemli bir rol oynamaktadır. Örneğin, sınıflandırma problemlerinde çapraz entropi (Cross-Entropy) fonksiyonu yaygın olarak kullanılırken, regresyon problemlerinde ortalama karesel hata

tercih edilir. Bu fonksiyonlar, modelin çıktıları ile gerçek değerler arasındaki farkı minimize etmeyi hedefler (Shin vd., 2023; Chollet, 2021). Model eğitimi süreci, verilerdeki örüntüleri ve ilişkileri öğrenmenin temelini oluşturur. Bu süreçte kullanılan algoritmalar ve optimizasyon teknikleri, modelin doğruluğunu ve genelleme yeteneğini doğrudan etkilemektedir (Aggarwal vd., 2020). Ayrıca, parametre optimizasyonu sırasında dikkatli bir hiper parametre ayarı, modelin performansını artırmada kritik bir rol oynamaktadır. Model eğitimi, yalnızca bir teknik işlem değil, aynı zamanda dikkatli bir değerlendirme ve inceleme gerektiren kapsamlı bir süreçtir (Kuhn & Johnson, 2013). Sonuç olarak, model eğitimi, ileri ve geri yayılım süreçlerinin bir döngü içinde tekrarlanmasıyla gerçekleşmektedir. Bu süreçte, modelin parametreleri, hata en aza indirilene kadar optimize edilir (El Naqa vd., 2015). Eğitim sürecinin amacı, modelin yalnızca eğitim verisinde değil, aynı zamanda daha önce görmediği yeni veriler üzerinde de yüksek doğrulukla tahmin yapabilmesini sağlamaktır (Jordan vd., 2015). Eğitim süreci tamamlandığında, model genelleme yeteneği kazanmış olur ve bu da onu gerçek dünya uygulamaları için kullanıma hazır hale getirmektedir. Başarılı bir model eğitimi, hem teori hem de uygulama açısından dengeli bir yaklaşım gerektirir ve projelerin başarısında kritik bir rol oynamaktadır (Zhou, 2021).

Regresyon modelleri, sürekli bir değer tahmin edilmesinde kullanılan temel makine öğrenmesi yöntemlerinden biridir. Bu modeller, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi analiz ederek gelecekteki değerleri tahmin etmek için matematiksel bir çerçeve sunmaktadır (Doan ve Kalita, 2015). Farklı veri türleri ve ilişki modellerine göre çeşitli regresyon yöntemleri bulunmaktadır. Doğrusal regresyon, bağımlı-bağımsız değişkenler arasındaki doğrusal ilişkiyi analiz etmek ve modellemek için en yaygın kullanılan temel yöntemlerden biridir (Ray, 2019). Bu yöntem, bağımlı değişkenin, bağımsız değişkenlerle bir doğrusal denklem üzerinden ifade edildiği basit bir yapı sunmaktadır. Örneğin, bir evin fiyatını metrekaresi ve bulunduğu bölgenin ekonomik durumu gibi değişkenlere dayanarak tahmin etmek için doğrusal regresyon kullanılabilir (Seber & Lee, 2012). Polinomsal regresyon, doğrusal modelin yetersiz kaldığı, doğrusal olmayan ilişkilerin bulunduğu durumlar için uygundur. Bu yöntem, bağımsız değişkenlerin polinom derecelerinin eklenmesiyle daha karmaşık ilişkileri modellemeye olanak tanımaktadır. Örneğin, bir ürünün satışlarının zamana bağlı olarak değişimini analiz etmek için polinomsal regresyon tercih edilebilir (James vd., 2013). Destek vektör regresyonu (DVR), doğrusal olmayan regresyon problemleri için sıklıkla kullanılan bir yöntemdir. Bu model, çekirdek (kernel) fonksiyonları yardımıyla veriyi daha yüksek boyutlu bir uzaya dönüştürerek doğrusal olmayan ilişkileri etkili bir şekilde modelleyebilir. DVR'nin genelleme yeteneği, onu hem doğruluk hem de performans açısından güçlü bir seçenek haline getirir (Smola & Schölkopf, 2004). Karar ağaçları, veri üzerinde hiyerarşik bir yapı oluşturarak tahmin yapan görselleştirilebilir bir model sunmaktadır. Her bir dal, veri setindeki belirli bir özelliği temsil eder ve nihai tahmin yaprak düğümünde gerçekleşir. Ancak, karar ağaçları aşırı öğrenme riskine açık olduğundan, dikkatli bir şekilde optimize edilmesi gerekir (Charbuty ve Abdulazeez,

2021). Rastgele orman, birden fazla karar ağacından oluşan bir ensembl öğrenme yöntemidir. Bu model, her ağacın tahminini birleştirerek daha yüksek doğruluk ve genelleme kapasitesi sunmaktadır. Özellikle büyük ve karmaşık veri setlerinde etkili sonuçlar elde etmek için sıkça tercih edilir. Rastgele ormanlar, karar ağaçlarının taşıdığı aşırı öğrenme riskini azaltırken, esneklik ve doğruluk açısından önemli avantajlar sağlamaktadır Ren vd., 2017).

Sınıflandırma modelleri, verileri belirli kategorilere ayırmak ve sınıf etiketlerini tahmin etmek için kullanılan makine öğrenmesi yöntemleridir. Geniş bir uygulama yelpazesine sahip olan bu modeller, farklı problem türlerine etkili çözümler sunar (Novaković vd., 2017). Lojistik regresyon, özellikle ikili (binary) sınıflandırma problemleri için kullanılan temel yöntemlerden biridir. Bu model, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi olasılıksal bir çerçevede ele alır. Örneğin, bir e-postanın istenmeyen e-posta olup olmadığını tespit etmek için sıklıkla tercih edilir. Basit yapısı ve yorumlanabilirliği, lojistik regresyonu birçok uygulama için uygun bir seçenek haline getirmektedir (Christodoulou vd., 2019).

Yapay sinir ağları, çok katmanlı yapılarıyla karmaşık sınıflandırma problemlerinde güçlü bir performans sunmaktadır. Özellikle derin öğrenme yaklaşımlarında kullanılan sinir ağları, giriş verilerindeki karmaşık ilişkileri öğrenme ve genelleme yeteneği ile birçok modern uygulamanın temelini oluşturmaktadır (Chen vd., 2017). K- En Yakın Komşular, veri noktalarının komşularına olan uzaklıklarını analiz ederek sınıflandırma yapan basit ama etkili bir modeldir. Parametresiz bir yöntem olan K- En Yakın Komşular, küçük veri setlerinde yüksek performans sergilerken, büyük veri setlerinde hesaplama maliyeti artabilir. Özellikle etiketli ancak az miktarda veri ile çalışılan projelerde tercih edilmektedir (Zhang, 2016). Naive Bayes, olasılık tabanlı yapısıyla özellikle metin sınıflandırma gibi uygulamalarda hızlı ve etkili sonuçlar sunmaktadır. Basit bir model olmasına rağmen, bağımsızlık varsayımına dayanarak güçlü bir performans sergiler ve düşük hesaplama maliyeti ile öne çıkmaktadır (Langseth ve Nielsen, 2006).

2.3.4. Derin Öğrenme

Makine öğrenmesinin bir alt dalı olan derin öğrenme, çok katmanlı yapay sinir ağları (YSA) aracılığıyla veriden karmaşık ilişkileri öğrenebilen güçlü bir yapay zeka tekniğidir (Schmidhuber, 2015). Büyük veri setleri ve yüksek hesaplama gücüyle çalışmaya uygun olan bu yöntem, karmaşık ve yüksek doğruluk gerektiren problemleri çözmek için geliştirilmiştir. Görüntü tanıma, doğal dil işleme, ses tanıma ve otonom araçlar ve benzeri birçok alanda devrim niteliğinde çözümler sunan derin öğrenme, giderek artan veri miktarıyla daha geniş bir uygulama alanına ulaşmaktadır (Rusk, 2016; LeCun vd., 2015).

Derin öğrenmenin temelini oluşturan yapay sinir ağları, insan beynindeki nöronların işleyişini taklit eden bir mimariye sahiptir. Sinir ağları, farklı işlevlere sahip

üç ana katmandan oluşur (LeCun vd., 2015). Ham verilerin modele aktarıldığı başlangıç katmanı Girdi Katmanı'dır. Verilerin işlendiği ve öğrenildiği ara katman Gizli Katmanlar'lardır (Kelleher, 2019). Modelin tahmin ettiği ya da sınıflandırdığı sonuçların üretildiği son katman Çıkış Katmanı'dır. Bu çok katmanlı yapı, verilerin modellenmesinde ve analitik görevlerde derin öğrenme algoritmalarının etkinliğini artırmaktadır (Goodfellow, 2016). Sınıflandırma modelleri, verileri belirli kategorilere ayırmak ve sınıf etiketlerini tahmin etmek için makine öğrenmesi kullanılırken, derin öğrenme ise katmanların çok sayıda olması sayesinde verinin karmaşık yapısını öğrenerek detaylı örüntüler çıkarmaktadır Şekil (2.10.).

Evrışimli Sinir Ağları (ESA), görüntü işleme ve video analizi gibi yapılandırılmamış veri türlerini anlamlandırmak için tasarlanmış güçlü bir derin öğrenme mimarisidir. ESA'lar, veriden anlamlı özellikler çıkararak sınıflandırma, segmentasyon ve nesne tanıma gibi görevlerde yüksek performans göstermektedir (Gupta vd., 2022). Özellikle görüntü tabanlı uygulamalarda, geleneksel yöntemlere kıyasla üstün başarılarıyla dikkat çeken bu mimariler, derin öğrenme devriminin öncüsü olarak kabul edilmektedir (Alzubaidi vd., 2021). ESA mimarisi, katmanların hiyerarşik bir düzenle yapılandırıldığı bir sistemdir ve her katman, veri üzerindeki farklı düzeylerdeki özellikleri öğrenmektedir. İlk katmanlar, temel görsel öğeleri (örneğin kenarlar, dokular) algılamak, daha derin katmanlar daha karmaşık yapıları (örneğin nesneler, yüzler) öğrenmektedir. Bu hiyerarşik öğrenme yeteneği, ESA'ların karmaşık görüntü analizi görevlerinde başarıyla kullanılmasını mümkün kılmaktadır (Krizhevsky vd., 2012). ESA'ların başarısının temelini oluşturan bu çok katmanlı yapı, görüntü verilerinden anlamlı örüntülerin etkili bir şekilde çıkarılmasını sağlamaktadır. Her katman, bir önceki katmandan elde edilen özellikleri işleyerek, daha sofistike ve yüksek seviyeli bilgileri temsil etmektedir (Alzubaidi vd., 2021). Bu özellik, ESA'ların sınıflandırma, segmentasyon ve nesne tanıma gibi görevlerde öne çıkmasını sağlamaktadır (Krizhevsky vd., 2012). Konvolüsyon Katmanları, görüntü üzerindeki küçük bölgelerden anlamlı özellikler çıkarmayı sağlamaktadır. Girdi veri üzerinde kayan bir filtre uygulanır ve her bir filtre, görüntünün belirli bir özelliğini (örneğin kenarlar, dokular) çıkarır (Ren vd., 2014). Konvolüsyon işlemi sonucunda bir "özellik haritası" oluşmaktadır. Örneğin, bir kenar algılama filtresi, görüntünün kenarlarını çıkarabilmektedir (Krizhevsky vd., 2012).


Aktivasyon Fonksiyonu, her konvolüsyon katmanından sonra, doğrusal olmayan bir dönüşüm uygulanmaktadır. ReLU (Rektifiye Lineer Ünite), en yaygın kullanılan aktivasyon fonksiyonudur. Negatif değerleri sıfıra çevirir ve pozitif değerleri olduğu gibi bırakmaktadır (Kılıçarslan vd., 2021).

$$\text{ReLU}(x) = x^+ = \max(0, x) = (x + |x|) / 2 \quad (2.1)$$

$$\text{ReLU}(x) = \{ x, \text{ if } x > 0$$

$$0, \text{ if } x \leq 0 \}$$

Havuzlama Katmanları, özellik haritalarını küçülterek, böylece hesaplama yükünü azaltıp ve modelin genelleme yeteneğini artırmakta kullanılmaktadır (Ren vd., 2014). Tam Bağlantılı Katmanlar, özellik haritalarını düzleştirip ve bir sinir ağı yapısına dönüştürmektedir. Bu katmanlar, çıkarılan özelliklere dayanarak sınıflandırma veya tahmin görevlerini gerçekleştirmektedir. Sınıflandırma problemlerinde, çıktı katmanı genellikle bir softmax aktivasyon fonksiyonu içerir ve her sınıf için olasılık değerleri üretmektedir (Krizhevsky vd., 2012).




Şekil 2.10. Makine Öğrenmesi ve Derin Öğrenme karşılaştırması

2.3.4.1. Popüler ESA Mimarileri


VGG, derin öğrenme alanında yaygın olarak kullanılan ve düzenli yapısıyla dikkat çeken bir ESA mimarisidir. İlk kez 2014 yılında ImageNet yarışmasında tanıtılan VGG, özellikle VGG16 (16 katmanlı) ve VGG19 (19 katmanlı) varyantlarıyla bilinmektedir (Hammad ve El-Sankary, 2018). Bu mimari, sabit boyutlarda (genellikle 3x3) filtreler kullanarak karmaşıklığı artırmadan etkili özellik çıkarımı yapmaktadır. Katmanlar arasında sabit bir derinlik artışı sağlanarak daha karmaşık örüntülerin öğrenilmesi mümkün hale gelmektedir. Havuzlama katmanları (max pooling), özellik haritalarının boyutunu küçültmek için kullanılırken, tam bağlantılı katmanlar sınıflandırma görevini yerine getirmektedir (Şekil 2.11.) (Sangeetha vd., 2020). VGG'nin basit ve düzenli yapısı, hem mimarinin kolay anlaşılmasını sağlar hem de küçük filtre boyutlarıyla güçlü özellik çıkarımı yapmasına olanak tanımaktadır (Rathinam vd., 2024). Derin bir mimariye sahip olması, VGG'yi daha karmaşık örüntüleri öğrenmek için ideal bir model haline getirirken, bu derinlik yüksek hesaplama gücü ve bellek gereksinimleri gibi dezavantajları da beraberinde getirmektedir (Upadhyay vd., 2024). Eğitim süresi uzun olup, model boyutu büyük olduğu için depolama ve çalıştırma maliyetleri yüksektir. Tüm

bu özelliklerine rağmen VGG, görüntü sınıflandırma, nesne algılama ve transfer öğrenimi gibi birçok alanda başarılı bir şekilde kullanılmaktadır (Rathinam vd., 2024; Upadhyay vd., 2024).




Şekil 2.11. Standart bir VGG-16 Ağ Mimarisi (Abu-Jamie ve Abu-Naser, 2022)

ResNet 2015 yılında Microsoft Araştırma tarafından geliştirilmiş ve derin öğrenme mimarilerinde “artık öğrenme” konseptiyle çığır açmaktadır. Bu mimari, derin ağlarda sıkça karşılaşılan “kaybolan gradyan” sorununu çözmeyi hedefleyerek, derin sinir ağlarının eğitim sürecini daha verimli hale getirmektedir. ResNet, katmanlar arasında doğrudan öğrenim yerine, giriş ve çıkış arasındaki farkı (artıkları) öğrenmeyi amaçlayan bir yaklaşım benimser (Şekil 2.12.) (Mascarenhas ve Agarwal, 2021). Artık bağlantılar (skip connections) sayesinde, bilgi akışı doğrudan desteklenir ve modelin daha hızlı öğrenmesi sağlanmaktadır. Bu yenilikçi yapı, ResNet’in derin ağlarda dahi etkili sonuçlar vermesine olanak tanımaktadır (He vd., 2016). ResNet, derin mimariler oluşturma kapasitesiyle dikkat çeker; örneğin ResNet-50, ResNet-101 ve ResNet-152 gibi varyantları, sırasıyla 50, 101 ve 152 katmandan oluşan modellerdir. Daha derin yapılarda bile yüksek performans sunan ResNet, derin öğrenme modellerinin optimizasyonunu büyük ölçüde iyileştirmektedir (Karadağ ve Özdemir, 2023). Ayrıca, VGG gibi mimarilere kıyasla daha düşük bir hesaplama yüküne sahiptir. Ancak, çok derin modellerde bileşenlerin karmaşıklığı artabileceği için yüksek GPU gücü gereksinimi devam etmektedir (Mascarenhas ve Agarwal, 2021). ResNet’in bu özellikleri, derin öğrenme mimarilerinde daha kapsamlı bir kullanım alanı ve daha etkili sonuçlar elde edilmesini sağlamaktadır.



Şekil 2.12. Resnet 50 mimarisinin temel yapısı (Sevinç ve Özyurt 2022).

DenseNet, katmanlar arasında yoğun bağlantılar kullanarak bilgi paylaşımını optimize eden yenilikçi bir ESA mimarisidir. Bu mimaride, her katman önceki katmanların tüm çıktısını girdi olarak alırken, kendi çıktısını da sonraki katmanlara iletir. Bu özellik, DenseNet'i diğer derin öğrenme mimarilerinden ayıran en önemli unsurdur (Wang ve Zhang, 2020). DenseNet'in temel yapı taşlarından biri olan Yoğun Bloklar (Dense Blocks), katmanlar arasında yoğun bilgi akışı sağlamaktadır. Her katman, önceki tüm katmanlardan gelen bilgiyi birleştirir ve bu birikimi sonraki katmanlara iletmektedir (Şekil 2.13.). Bu yaklaşım, modelin gradyanların daha iyi akışını sağlamasına ve daha verimli bir öğrenme süreci gerçekleştirmesine olanak tanımaktadır. Ayrıca, bu bağlantı yapısı, modelin parametre sayısını azaltarak parametre verimliliğini artırır ve özelliklerin yeniden kullanımını teşvik etmektedir (Mittal vd., 2024). Parametre verimliliği ile daha az hesaplama gücü ve bellek gerektirirken, aşırı öğrenme'e karşı dayanıklılığıyla dikkat çekmektedir. Derinlik artırıldığında bile performansta genellikle bir azalma görülmemesi, DenseNet'in özellikle derin mimarilerde tercih edilmesine neden olmaktadır. Bununla birlikte, çok yoğun bağlantılar, büyük ölçekli ağlarda hesaplama maliyetini artırabilir ve daha karmaşık bir mimariye sahip olması, uygulama sürecini zorlaştırabilmektedir (Sujatha ve Rao, 2023). DenseNet'in yoğun bağlantılara dayalı yapısı, özellikle sınırlı donanım kaynaklarıyla çalışırken yüksek doğruluk ve verimlilik sunarak, derin öğrenme alanında önemli bir alternatif olarak öne çıkmaktadır (Wang ve Zhang, 2020). Tüm bu mimariler karşılaştırıldığında herbirinin farklı pozitif ve negatif yönleri ortaya çıkmaktadır (Çizelge 2.1).



Şekil 2.13. DenseNet-201 Mimarisi (Wang ve Zhang, 2020)

Çizelge 2.1. ESA mimarileri karşılaştırılması

Özellik	VGG	ResNet	DenseNet
Geliştirme Yılı	2014	2015	2017
Mimari	Sabit filtre boyutları	Artık bloklar	Yoğun bağlantılar
Performans	Daha az verimli	Daha derin ağlarda etkili	Yüksek parametre verimliliği
Parametre Sayısı	Çok yüksek	Orta	Daha düşük
Kullanım Alanı	Görüntü sınıflandırma	Genel uygulamalar	Medikal görüntü analizi

2.3.4.2. Model Testi

Model testi, makine öğrenmesi sürecinin hayati bir aşamasıdır ve modelin eğitimden sonra performansını değerlendirmek için gerçekleştirilmektedir. Bu süreçte, model daha önce hiç görmediği test verisi üzerinde çalıştırılır ve doğruluk, genelleme yeteneği ve hata oranı gibi temel metrikler üzerinden analiz edilmektedir (Chen vd., 2017). Model testi, modelin gerçek dünya verileri üzerindeki başarısını öngörmek ve herhangi bir aşırı öğrenme durumu olup olmadığını belirlemek açısından kritik öneme sahiptir. Model testi sürecinde, veri seti genellikle eğitim ve test setlerine ayrılmaktadır. Test seti, modelin eğitimi sırasında kesinlikle kullanılmaz ve bağımsız bir şekilde tutulmaktadır (Ren vd., 2017). Bu ayrım, modelin performansının objektif bir şekilde

değerlendirilmesini sağlamaktadır. Genellikle, veri setinin %70-80'i eğitim, %20-30'u ise test amacıyla kullanılmaktadır. Ayrıca, hiperparametre optimizasyonu için doğrulama seti (validation set) kullanılabilir (Nasteski, 2017). Ancak modelin nihai performansı yalnızca test seti üzerinden değerlendirilir. Bu yaklaşım, modelin genelleme kapasitesini doğru bir şekilde ölçmeyi mümkün kılmaktadır. Test verisi modele verilip ve modelin tahminleri kaydedilmektedir (Braiek ve Khomh, 2020). Test setindeki gerçek değerlerle modelin tahmin ettiği değerler karşılaştırılmaktadır. Modelin doğruluğunu ve genelleme yeteneğini değerlendirmek için performans metrikleri hesaplanır. Bunlar; Doğruluk (Accuracy), tüm tahminlerin ne kadarının doğru olduğunu göstermektedir. Sınıflandırma problemleri için sık kullanılmaktadır (Goodfellow vd., 2016). Hata Oranı (Error Rate), yanlış tahminlerin oranını göstermektedir. Kesinlik (Precision), pozitif olarak tahmin edilenlerin gerçekten pozitif olma oranıdır. Yanlış pozitifleri azaltmaya odaklanmaktadır. Duyarlılık (Recall), gerçek pozitiflerin ne kadarının doğru tahmin edildiğini ölçmektedir. Yanlış negatifleri azaltmaya odaklanmaktadır. F1-Skoru, kesinlik ve duyarlılığın dengeli bir şekilde değerlendirilmesini sağlamaktadır (Erickson ve Kitamura, 2021).

Tahmin ve değerlendirme, makine öğrenmesi sürecinin çıktısını analiz ederek modelin gerçek dünya verileri üzerindeki performansını doğrulamayı amaçlayan son adımdır. Bu aşamada, model, daha önce görmediği veri üzerinde çalıştırılır ve elde edilen tahminler, çeşitli performans metrikleri aracılığıyla değerlendirilmektedir (Goodfellow vd., 2016). Temel hedef, modelin doğruluğunu, genelleme yeteneğini ve hatalarını kapsamlı bir şekilde analiz etmektir. Tahmin sürecinde model, yeni ve gerçek dünya verileriyle test edilmektedir. Regresyon problemlerinde model, sürekli değerler tahmin ederken (örneğin, bir evin fiyatı), sınıflandırma problemlerinde ise kategorik etiketler üretmektedir (örneğin, bir e-postanın spam olup olmadığı). Örneğin, bir sağlık uygulamasında, model, tıbbi görüntülerden bir tümörün malign ya da benign olduğunu tahmin edebilmektedir. Bu tahminler, modelin gerçek dünya koşullarında ne kadar etkili olduğunu ölçmek için kritik bir adım sağlamaktadır (Rácz vd., 2019).

Modelin ürettiği tahminler, gerçek sonuçlarla karşılaştırılarak değerlendirilir. Bu süreçte, tahmin edilen değerler ile gerçek değerler arasındaki farklar (hatalar) tespit edilir ve analiz edilmektedir. Ayrıca, bazı modeller, her sınıf için olasılık tabanlı skorlar üretebilir. Örneğin, lojistik regresyon veya rastgele orman modelleri, bir verinin belirli bir sınıfa ait olma olasılığını %0 ile %100 arasında bir değerle ifade edebilmektedir. Bu olasılıklar, karar eşiği belirlenerek sınıflandırma işlemi için kullanılabilir. Örneğin, bir spam filtresi modeli, bir e-postanın spam olma olasılığını değerlendirerek karar vermektedir. Bu adımlar, modelin güçlü ve zayıf yönlerini belirlemeye ve geliştirilmesi gereken alanlara ışık tutmaya yardımcı olmaktadır (Erickson ve Kitamura, 2021).

2.3.4.3. Sınıflandırma Modelleri için Performans Değerlendirme Metrikleri

Sınıflandırma algoritmalarında elde edilen sonuçların karşılaştırılabilmesi için çeşitli değerlendirme metriklerine ihtiyaç duyulmaktadır. Bu metrikler, modelin performansını ölçmek ve başarı düzeyini belirlemek amacıyla kullanılır. Sınıflandırma sonuçları genellikle karışıklık matrisi ile ifade edilir. Karışıklık matrisinde, örneklerin gerçek sınıfları sütunlarda, model tarafından tahmin edilen sınıflar ise satırlarda gösterilmektedir. Bu çalışmada, sınıflandırma performansını değerlendirmek için F-ölçümü ve doğruluk değerleri kullanılmış olup, bu değerler karışıklık matrisi temel alınarak hesaplanmıştır(Şekil 2.14.).

- Gerçek Pozitif (GP): Pozitif olan bir parametrenin model tarafından da pozitif olarak tahmin edilmesidir (Yenikaya, 2024).
- Gerçek Negatif (GN): Negatif olan bir parametrenin model tarafından da negatif olarak tahmin edilmesidir (Yenikaya, 2024).
- Yanlış Pozitif (YP): Negatif olan bir parametrenin model tarafından pozitif olarak tahmin edilmesidir (Yenikaya, 2024).
- Yanlış Negatif (YN): Pozitif olan bir parametrenin model tarafından negatif olarak tahmin edilmesidir (Yenikaya, 2024).

		Pozitif	Negatif
Gerçek Değer	Pozitif	DP	YP
	Negatif	YN	DN
		Tahmin Edilen Değer	

Şekil 2.14. Karışıklık matrisi

Karışıklık matrisi, etiketli verilerin sınıflandırılması sonucunda, modelin tahmin ettiği sınıflarla gerçek sınıflar arasındaki ilişkiyi gösteren bir tablodur.

Doğruluk, modelin doğru sınıflandırdığı örneklerin, toplam örnek sayısına oranı olarak ifade edilir. İkili ve çok sınıflı sınıflandırma modellerinde yaygın olarak kullanılmaktadır (Cihan, 2018).

$$\text{Doğruluk} = (DP + DN) / (DP + DN + YP + YN) \quad (2.2)$$

Kesinlik, modelin pozitif olarak sınıflandırdığı örneklerden kaç tanesinin gerçekten pozitif olduğunu göstermektedir (Cihan, 2018):

$$\text{Kesinlik} = \text{DP} / (\text{DP} + \text{YP}) \quad (2.3)$$

Duyarlılık, pozitif sınıfa ait gerçek örneklerin ne kadarının model tarafından doğru tahmin edildiğini göstermektedir (Cihan, 2018):

$$\text{Duyarlılık} = \text{DP} / (\text{TP} + \text{YN}) \quad (2.4)$$

F1-Skoru, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıyla hesaplanmaktadır (Cihan, 2018):

$$F1 = 2 * (\text{Kesinlik} * \text{Duyarlılık}) / (\text{Kesinlik} + \text{Duyarlılık}) \quad (2.5)$$

2.4. Literatürden Örnekler

MRI verileri üzerinde gerçekleştirilen çalışmalarda, derin öğrenme tabanlı modellerin, geleneksel yöntemlere kıyasla daha yüksek doğruluk oranları ve analiz hızı sunduğu görülmüştür. Bu literatür taramasında, yapay zeka ve derin öğrenme yaklaşımlarının beyin tümörlerinin teşhis ve sınıflandırılmasındaki etkileri detaylı bir şekilde ele alınmıştır. Ayrıca, kullanılan modellerin avantajları ve sınırlamaları incelenerek, bu alanda daha ileri düzeyde araştırmalar için yönlendirici bilgiler sunulmuştur. Litjens ve arkadaşlarının yayımladığı “A Survey on Deep Learning in Medical Image Analysis” başlıklı çalışma, derin öğrenme yöntemlerinin tıbbi görüntü analizindeki rolünü inceleyen kapsamlı bir literatür taramasıdır. Çalışma, özellikle derin öğrenme modellerinden ESA’nın sınıflandırma, segmentasyon ve nesne tespiti gibi görevlerde gösterdiği başarıları odaklanmıştır. Büyük veri setleri üzerinde eğitilen bu modellerin, tıbbi görüntüleme süreçlerinde hem doğruluk oranını hem de işlem hızını önemli ölçüde artırdığı vurgulanmıştır. Bununla birlikte, modellerin genelleme kapasitesi, sınırlı veri ile çalışma zorlukları ve klinik uygulamalara entegrasyon süreçleri gibi konular detaylı bir şekilde tartışılmıştır (Litjens vd. 2017). Bu değerlendirmeler, tez kapsamında kullanılan VGG16, ResNet50 ve DenseNet201 modellerinin seçimine rehberlik etmiş ve bu modellerin uygulanabilirliğini desteklemiştir. He ve arkadaşlarının yayımladığı çalışmada, residual öğrenme çerçevesine dayalı ResNet modelleri, derin sinir ağlarının eğitimi ve performansında önemli bir çalışma gerçekleştirmiştir. Residual ağlar, gradyan kaybolması gibi sorunları önlemek için geliştirilmiş ve derin ağların verimli bir şekilde eğitilmesini sağlamıştır. ImageNet veri setinde test edilen 152 katmanlı ResNet, %20.25 hata oranıyla üstün bir performans göstermiştir. Artık bağlantılar, ağırlık bilgisi akışını güçlendirerek eğitim sürecini kolaylaştırmış ve yüksek doğruluk oranlarına ulaşılmasını sağlamıştır. CIFAR-10 veri setindeki deneylerde ise ResNet, 1000’den fazla

katmana ölçeklenebilmiş ve aşırı öğrenme veya doğruluk kaybı gibi sorunlar yaşanmamıştır. Bu model, görüntü sınıflandırmanın yanı sıra nesne tespiti ve segmentasyon gibi diğer bilgisayarla görme görevlerinde de önemli sonuçlar elde etmiştir (He vd., 2016). DenseNet modeli ile ilgili, her katmanı bir önceki tüm katmanlara bağlayarak geleneksel mimarilerden ayrılan bir çalışma yapılmıştır. Bu yoğun bağlantılar, özellik paylaşımını artırarak öğrenme sürecini hızlandırmış, gradyan kaybolmasını azaltmış ve öğrenilen özelliklerin yeniden kullanılmasını sağlamıştır. DenseNet, daha az parametreyle yüksek performans sunarak bellek verimliliği sağlamış ve aşırı öğrenme riskini düşürmüştür. CIFAR-10, CIFAR-100, SVHN ve ImageNet gibi veri setlerinde test edilen model, doğruluk oranlarını artırırken derinlik artışına gerek duymamıştır. Özellikle sınıflandırma dışında genelleme kapasitesini de artırarak, daha az parametreyle etkili sonuçlar elde etmiştir (Huang vd., 2017). Yapılan başka bir araştırmada, ham piksel girdilerini işleyerek oyun stratejileri geliştiren ve Atari oyunlarında insan seviyesini aşan bir yapay zeka sistemi tanıtılmıştır. Çalışmanın temelinde, Q-öğrenme algoritmasını derin sinir ağlarıyla birleştiren DQA yer almıştır. Modelin başarısında, öğrenme sürecini stabilize eden deneyim tekrarı ve hedef ağlar yöntemleri öne çıkmıştır. DQA, 49 Atari oyununda test edilmiş ve birçok oyunda insan performansını aşmıştır. Örneğin, Breakout oyununda optimal bir strateji öğrenerek maksimum puana ulaşmıştır. Bu başarı, modelin genelleme kapasitesini ve farklı dinamiklere uyum sağlama yeteneğini göstermiştir (Mnih vd., 2015).

Beyin tümörlerinin sınıflandırılması yapılan bir çalışmada hafif ve yüksek doğruluklu bir model olan GliomaESA tanıtılmıştır. Model, BraTS 2020 veri seti üzerinde test edilmiş ve %99.1569 doğruluk oranına ulaşmıştır. Az parametre ve düşük hesaplama maliyeti gereksinimiyle tasarlanan GliomaESA, sınırlı donanıma sahip klinik ortamlarda kullanım için uygundur. Çalışmada, modelin açıklanabilir yapay zeka teknikleriyle entegre edilmesidir. SHAP ve Grad-CAM++, modelin hangi özellik ve bölgeleri dikkate alarak karar verdiğini görselleştirerek klinisyenlere sonuçları daha iyi anlama imkânı sunmuştur. Veri ön işleme ve artırma teknikleriyle modelin doğruluğu ve genelleme kapasitesi artırılmış, aşırı öğrenme riski azaltılmıştır. Hafif yapısı, yüksek doğruluğu ve açıklanabilirliği sayesinde GliomaESA, özellikle kaynakların sınırlı olduğu sağlık kuruluşları ve gelişmekte olan bölgeler için pratik bir çözüm sunmaktadır. Çalışma, yapay zekâ destekli teşhis sistemlerinin güvenilirliğini artırarak beyin tümörü teşhisinde erişilebilir ve etkili bir yaklaşım sunmuştur (Rahman ve Masum, 2024). Pekiştirmeli öğrenmenin temel prensiplerinin anlatıldığı ve uygulama alanlarının kapsamlı bir şekilde ele alındığı bir çalışmada, ödül tabanlı öğrenmenin, bir ajanın çevresiyle etkileşim kurarak deneyimlerinden öğrenmesini ve en iyi aksiyonları belirlemesini sağladığını vurgulamıştır. Bu bağlamda, Q-öğrenme algoritması, herhangi bir model gerektirmeden bir değer tablosu (Q-tablosu) oluşturarak en etkili aksiyonları öğrenme yeteneğiyle öne çıkmıştır. Çalışma, pekiştirmeli öğrenmenin tıbbi teşhis süreçlerinde, özellikle karmaşık karar mekanizmaları gerektiren beyin tümörü sınıflandırması gibi görevlerde önemli bir potansiyele sahip olduğunu göstermiştir. Q-öğrenme, ödül-ceza mekanizmasıyla, tıbbi görüntülerdeki kritik farklılıkları tespit edebilmekte ve doğruluk oranını

artırabilmektedir. Ayrıca, çevresel değişikliklere adaptasyon ve kendini optimize etme yeteneği, algoritmanın uzun vadeli doğruluk sağlamasını mümkün kılmaktadır (Sutton ve Barto, 2018). Nancy ve Maheswari çalışmasında, transfer öğrenme tabanlı ESA modellerinin beyin tümörlerinin segmentasyonu ve sınıflandırılmasındaki etkinliğini incelemiştir. BraTS 2019, 2020 ve 2021 veri setlerinden elde edilen MRI görüntüleriyle yapılan çalışmada, veri artırma teknikleri kullanılarak aşırı öğrenme riski azaltılmıştır. Segmentasyonda VGG-19 modelinin katmanları, özellik çıkarımında ise Öznitelik Duyarlı Dikkat Mekanizması ve Modelden Bağımsız Kavram Çıkarıcı yöntemleri kullanılmıştır. Bu yenilikçi yaklaşımla tümörün farklı bölgelerinin başarılı şekilde sınıflandırıldığı ve modelin sırasıyla %96.20, %98.20 ve %99.40 doğruluk oranlarına ulaştığı belirtilmiştir. Segmentasyon başarısı, Dice Benzerlik Katsayısı (Dice Similarity Coefficient) metriğiyle %91.06, %91.40 ve %94.86 olarak ölçülmüştür (Nancy ve Maheswari, 2025). Şener ve Ergen'in gerçekleştirdiği çalışma, beyin tümörlerinin MRI üzerinden tespiti ve sınıflandırılması için derin öğrenme tabanlı bir yaklaşım sunmaktadır. Araştırmada, VGG-19 mimarisi temel alınarak bir model geliştirilmiş ve glioma, meningioma, hipofiz tümörleri ile tümör bulunmayan beyin görüntülerini içeren açık kaynaklı bir veri seti üzerinde test edilmiştir. Model, bu veri seti üzerinde eğitilmiş ve %95 doğruluk oranına ulaşmıştır (Şener ve Ergen, 2022). Yapılan bir başka çalışmada, beyin tümörlerinin teşhisinde MRI verilerinden yararlanarak transfer öğrenme tabanlı derin öğrenme algoritmalarının performansını incelemiştir. Araştırma, MRI'in yüksek çözünürlüklü görüntüleme kapasitesiyle beyin tümörlerinin teşhisinde etkili bir araç olduğunu vurgulamıştır. DenseNet-121 modeli, doğru ve güvenilir sınıflandırma görevlerinde öne çıkmış, geniş bir MRG veri setiyle yapılan testlerde yüksek doğruluk ve hassasiyet oranlarına ulaşmıştır. (Demirel ve Soylu 2024). Rehman ve arkadaşlarının çalışmasında, meningioma, glioma ve hipofiz tümörlerinin sınıflandırılmasında AlexNet, GoogLeNet ve VGGNet gibi ESA mimarileri incelenmiştir. Çalışma, MRI dilimlerinden oluşan Figshare veri seti üzerinde transfer öğrenme yöntemlerini değerlendirerek ince ayar ve dondurma tekniklerini araştırmıştır. Sonuçlar, ince ayarlı VGG16 modelinin sınıflandırma ve tespit açısından en yüksek performansı sergileyerek %98.69 doğruluk oranına ulaştığını göstermiştir. Bu sonuçlar VGG16'nın bu tür görevlerde etkili bir model olduğunu ortaya koymaktadır (Rehman vd., 2021). Abiwinanda ve arkadaşlarının çalışmasında, beyin tümörlerinin sınıflandırılmasında beş farklı ESA mimarisi değerlendirilmiş ve en yüksek doğruluğun, Mimari 2 ile elde edildiği belirtilmiştir. Bu model, iki evrimsel katman, bir ReLU katmanı, bir max-pooling katmanı ve 64 gizli nörondan oluşmaktadır. Çalışmada, eğitim setinde %98.51, doğrulama setinde ise %84.19 doğruluk oranına ulaşılmıştır. Bu bulgular, ESA mimarilerinin yapısal tasarımının sınıflandırma performansında belirleyici bir faktör olduğunu ve Mimari 2'nin beyin tümörü sınıflandırmasında etkili bir model olarak öne çıktığını göstermektedir (Abiwinanda vd., 2019). Ghosal ve arkadaşları, MR görüntülerinde glioma, hipofiz tümörü ve meningioma sınıflandırması için sıkma ve uyarma mekanizması kullanan ResNet-101 tabanlı bir derin sinir ağı yaklaşımı önermiştir. Performansı artırmak için sıfır merkezleme yoğunluğu normalizasyonu ve veri artırma teknikleri uygulanmıştır.

Deneysel sonuçlar, sınıflandırma doğruluğu, özgüllük ve duyarlılık açısından diğer yöntemlere kıyasla belirgin iyileşmeler sağlamıştır (Ghosal vd., 2019). Krishnapriya ve arkadaşları çalışmasında ise, VGG-19, VGG-16, ResNet-50 ve Inception V3 gibi önceden eğitilmiş derin evrişimli sinir ağı (DESA) modellerinin beyin MR görüntülerinin sınıflandırılmasındaki performansını değerlendirmiştir. Araştırmada, veri artırma ve transfer öğrenme teknikleri kullanılarak bu modellerin sınıflandırma doğruluğu optimize edilmiştir. Çalışma, derin öğrenme tabanlı yöntemlerin beyin tümörü sınıflandırmasında etkinliğini ve genelleme kapasitesini artırabileceğini göstermiştir (Krishnapriya vd., 2023).

Literatürde, yapay zeka ve derin öğrenme modellerinin beyin tümörlerinin teşhis ve sınıflandırılmasındaki başarısı birçok çalışma ile kanıtlanmıştır (Rehman vd., 2020; Litjens vd., 2017; Rasool vd., 2022; Zhou vd., 2021). Özellikle VGG16, ResNet50 ve DenseNet201 gibi modern mimariler, yüksek doğruluk oranlarıyla geleneksel yöntemlere kıyasla önemli bir ilerleme sunmaktadır (Sujatha vd., 2023; Sharma 2023; Mascarenha vd., 2021; Upadhyay vd., 2024). Derin öğrenme, büyük veri setlerinden anlamlı örüntüler çıkararak sınıflandırma ve segmentasyonda etkin bir rol oynamaktadır. Ayrıca, pekiştirmeli öğrenme gibi ödül-ceza tabanlı yaklaşımlar, belirsizliklerin fazla olduğu durumlarda hızlı ve optimize edilmiş çözümler sunmaktadır. Yapay zeka yöntemleri, teşhis doğruluğunu artırmanın yanı sıra süreçleri hızlandırarak klinik uygulamalarda daha güvenilir ve pratik sonuçlar sağlamaktadır. Bu tez çalışmasında, literatürdeki güçlü yöntemler bir araya getirilmiş ve optimize edilmiş bir tanı sistemi geliştirilmiştir. VGG16, ResNet50 ve DenseNet201 mimarileri Q-öğrenme tabanlı algoritmayla entegre edilerek hem doğruluk hem de hız açısından daha etkili bir sistem tasarlanmıştır. Bu yenilikçi yaklaşımın, beyin tümörleri teşhisinde klinik uygulamalara önemli katkılar sağlaması beklenmektedir.

3. MATERYAL VE METOT

Bu çalışmada, “glioma, meningioma, sağlıklı (no tumor), ve pituitary” sınıflarını içeren üç farklı beyin tümörü veri seti (Cheng vd., 2016; Sharif vd., 2020; Zeineldin 2022) kullanılmıştır. Toplamda 7.168 MR görüntüsü ve derin öğrenme modelleri (VGG16, ResNet50, DenseNet201) kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Model geliştirme, eğitimi ve değerlendirme süreçleri MATLAB 2024.1a platformu kullanılarak yürütülmüştür. Ayrıca, pekiştirmeli öğrenme yöntemiyle Q-tablosu oluşturularak, modele verilen bir görüntünün hangi tümör sınıfına yüzdelik olarak daha yakın olduğunun belirlenmesi hedeflenmiştir.

3.1. Veri Seti ve Önleme

Bu çalışmada kullanılan 3 veri seti, “glioma, meningioma, sağlıklı (no tumor), ve pituitary” olmak üzere dört birincil beyin tümörü sınıfından oluşmaktadır. Her bir görüntü, beyin tümörü türüne göre özenle etiketlenmiştir. Sınıflar arasında yeterli sayıda örnek bulunması, model eğitimi sırasında karşılaşılabilecek veri sorunlarının önüne geçmek amacıyla özellikle sağlanmıştır. Bu düzenleme, modelin her bir sınıfı doğru şekilde öğrenmesi ve genelleme yeteneğini artırması için kritik bir önem taşımaktadır. Tüm görüntüler, MRI teknolojisiyle elde edilmiş olup, farklı çözünürlüklerde ve formatlarda sunulmuştur. Görüntülerin bazıları gri tonlamalı, bazıları ise renkli (RGB) formatta bulunmakla birlikte, model eğitiminde tutarlılığı sağlamak amacıyla tüm görüntüler renkli formatta işlenmiş ve üç kanallı olarak temsil edilmektedir. Bu dönüşüm, modellerin giriş gereksinimlerine uygunluğu sağlamak için önemli bir adım oluşturmaktadır. Tüm görüntüler, MATLAB’ın augmentedImageDatastore fonksiyonu kullanılarak 224×224 piksel boyutlarına yeniden ölçeklendirilmiştir. Bu standart boyut, VGG16, ResNet50 ve DenseNet201 gibi derin öğrenme modellerinin varsayılan giriş boyutlarıyla uyumluluk sağlamak amacıyla seçilmiştir. Görüntülerin piksel değerleri, genellikle 0 ile 255 arasında tamsayılar olarak ifade edilmektedir. Bu değerler, modelin hesaplamalarını kolaylaştırmak ve daha iyi bir öğrenme süreci sağlamak amacıyla [0, 1] aralığına normalize edilmiştir. MATLAB ortamında bu normalizasyon, im2double fonksiyonları kullanılarak gerçekleştirilmiştir. Bu ön işleme adımları, modelin verilerden doğru bir şekilde öğrenebilmesi için kritik bir hazırlık süreci olarak değerlendirilmektedir.

3.2. Veri Ayırma Süreci

Veri seti, modelin eğitimi ve performansının değerlendirilmesi amacıyla üç ana gruba ayrılmıştır; eğitim seti (%70), doğrulama seti (%15) ve test seti (%15). Bu ayırım, modelin hem öğrenme sürecini optimize etmek hem de genelleme yeteneğini doğru bir şekilde değerlendirmek için önemli bir süreçtir.

Eğitim Seti, veri setinin %70’ini oluşturmaktadır. Modelin sınıflar arasındaki ilişkileri öğrenmesi için kullanılmıştır. Bu aşamada model, giriş görüntüleri ile bu

görüntülere karşılık gelen sınıf etiketleri arasındaki bağlantıları öğrenmek üzere optimize edilmiştir. Eğitim süreci, modelin temel öğrenme yeteneklerini geliştirmeyi ve hataları minimize etmeyi hedeflemiştir.

Doğrulama Seti, veri setinin %15'ini oluşturmaktadır. Bu grup, modelin hiperparametre ayarlarını doğrulamak ve aşırı öğrenme riskini azaltmak için kullanılmıştır. Doğrulama seti, modelin eğitim sırasında bağımsız performansını değerlendirmeyi ve gerektiğinde ayarların optimize edilmesini sağlamayı amaçlamıştır.

Test Seti, veri setinin kalan %15'i, modelin genel performansını ve gerçek dünya verileri üzerindeki başarısını değerlendirmek için test seti olarak kullanılmıştır. Test seti, eğitim ve doğrulama süreçlerinden tamamen bağımsız tutulmuş olup, modelin genelleme yeteneğini ölçmek ve sonuçların gerçekçi bir değerlendirmesini yapmak için kritik bir rol oynamaktadır. Veri ayırma işlemi, MATLAB'ın splitEachLabel fonksiyonu kullanılarak gerçekleştirilmiştir. Bu fonksiyon, her bir sınıfın aynı oranda temsil edilmesini sağlayarak dengeli bir veri dağılımı oluşturmuştur.

3.3. Görüntü Çeşitliliği ve Veri Artırma

Modelin sınıflar arasında daha iyi genelleme yapabilmesi için eğitim verisi üzerinde veri artırma (data augmentation) işlemleri uygulanmıştır. Bu işlemler, modelin farklı görüntü varyasyonlarına karşı dayanıklılığını artırmak ve eğitim sürecinde aşırı öğrenmeyi önlemek amacıyla tasarlanmıştır. Uygulanan veri artırma işlemleri; görüntüler, 0° ile 30° arasında rastgele döndürülerek modele farklı açılardan sunulmuştur. Bu işlem, modelin yön varyasyonlarına karşı daha esnek hale gelmesine katkı sağlamıştır. Parlaklık değişimi, görüntülerin parlaklık değerleri %80 ile %120 arasında rastgele değiştirilmiştir. Bu sayede, modelin farklı ışık koşullarında daha iyi performans göstermesi hedeflenmiştir. Görüntüler, yatay eksende rastgele çevrilmiştir. Bu teknik, görüntülerin simetrik varyasyonlarını tanıma yeteneğini artırmaktadır. Rastgele Kırpma, görüntülerin belirli bir yüzdesi rastgele kırıldı ve modele bu şekilde sunulmuştur. Bu işlem, modelin görüntülerin farklı bölümlerine odaklanmasını sağlayarak öğrenme sürecini zenginleştirmektedir. Bu veri artırma işlemleri, modelin eğitim sürecinde daha geniş bir veri yelpazesini görmesini sağlamaktadır ayrıca genelleme yeteneğini artırıp modelin gerçek dünya verilerine karşı daha dayanıklı hale gelmesine yardımcı olmaktadır.

3.4. Model Mimarisinin Geliştirilmesi

Bu çalışmada, MATLAB'ın Deep Learning Toolbox'ı kullanılarak, önceden eğitilmiş derin öğrenme modelleri (VGG16, ResNet50 ve DenseNet201) ile beyin tümörü sınıflandırma işlemi gerçekleştirilmiştir. Modeller, transfer öğrenme yaklaşımı kullanılarak başlangıç ağırlıkları olarak ImageNet, veri seti üzerinde eğitilmiş ağırlıklarla başlatılmıştır. Bu sayede, modellerin büyük veri setlerinden elde edilen genel özellikleri öğrenmesi sağlanmıştır ve ardından, beyin tümörü sınıflarına özel olarak yeniden

eğitilmiştir. Model mimarileri, dört sınıfı ayırt edebilmek için özelleştirilmiştir ve bu doğrultuda her bir modelin son katmanları güncellenerek, sınıflandırma görevine uygun hale getirilmiştir. Bu süreçte, sınıflandırma katmanı, sınıf sayısına (dört) uygun şekilde yeniden yapılandırılmıştır ve modeller, beyin tümörü verileri üzerinde daha hassas ve doğru tahminler yapabilecek şekilde optimize edilmiştir.

VGG16, sabit boyutlu filtreler (3x3) kullanarak özellik çıkarımı yapan, derin ve düzenli bir ESA mimarisidir. MATLAB’da VGG16 fonksiyonu aracılığıyla çağrılan bu model, bu çalışmada aşağıdaki şekilde özelleştirilmiştir:

- Modelin Yüklenmesi: MATLAB’ın VGG16 fonksiyonu kullanılarak VGG16 modeli yüklenmiştir.
- Transfer Öğrenme: Model, ImageNet veri seti üzerinde eğitilmiş önceden tanımlı ağırlıkları kullanarak transfer öğrenme yöntemiyle yeniden yapılandırılmıştır.
- Katmanların Uyarlanması: VGG16 modelinin son katmanları, ImageNet için tasarlanmış 1000 sınıf yerine beyin tümörü veri setindeki dört sınıfı sınıflandıracak şekilde düzenlenmiştir.
- Tam Bağlantılı Katman: Modelin son tam bağlantılı katmanı 4 nöron içerecek şekilde değiştirilmiştir.
- Sınıflandırma Katmanı: Sınıflandırma katmanı, beyin tümörü veri setine uygun olarak yeniden yapılandırılmıştır.
- Giriş Boyutunun Uyarlanması: Model, beyin tümörü veri setindeki 224×224 piksel boyutundaki giriş görüntülerine uyum sağlayacak şekilde optimize edilmiştir.

ResNet50, 50 katmandan oluşan derin bir ESA mimarisi olup, artık bloklar kullanarak kaybolan gradyan problemini çözmek için tasarlanmıştır. Bu çalışmada, MATLAB’da resnet50 fonksiyonu kullanılarak çağrılan model, şu şekilde özelleştirilmiştir:

- Modelin Yüklenmesi: ResNet50, MATLAB’ın resnet50 fonksiyonu ile yüklenmiştir.
- Transfer Öğrenme: ImageNet üzerinde eğitilmiş önceden tanımlı ağırlıklar, transfer öğrenme yöntemiyle beyin tümörü veri setine uygun şekilde yeniden kullanılmıştır.
- Tam Bağlantılı Katman: Modelin son tam bağlantılı katmanı 4 nöron içerecek şekilde güncellenmiştir.

- Sınıflandırma Katmanı: Sınıflandırma katmanı, dört sınıflı sınıflandırmaya uygun olarak değiştirilmiştir.
- Artık Blokların Optimizasyonu: ResNet50'nin mimarisinde yer alan artık bloklar, eğitim verisi ile uyumlu şekilde korundu ve optimize edilmiştir. Bu bloklar, modelin derin mimarilerde performans kaybı yaşamadan etkili bir şekilde öğrenmesini sağlamıştır.
- Giriş Boyutunun Uyarlanması: Model, veri setindeki 224×224 piksel boyutundaki giriş görüntülerine uygun hale getirilmiştir.

DenseNet201, her bir katmanın önceki tüm katmanlarla yoğun bağlantılar kurduğu, daha az parametre ile yüksek performans sunan bir diğer ESA mimarisidir. Bu çalışmada, MATLAB'da densenet201 fonksiyonu kullanılarak çağrılan model şu şekilde özelleştirilmiştir:

- Modelin Yüklenmesi: DenseNet201 modeli, MATLAB'ın Densenet201 fonksiyonu aracılığıyla yüklenmiştir.
- Transfer Öğrenme: Model, ImageNet üzerinde eğitilmiş önceden tanımlı ağırlıklarla başlatılmış ve transfer öğrenme yöntemiyle beyin tümörü veri setine uygun hale getirilmiştir.
- Tam Bağlantılı Katman: Modelin tam bağlantılı katmanı, dört sınıflı sınıflandırmaya uygun olacak şekilde yeniden düzenlenmiştir.
- Sınıflandırma Katmanı: Son sınıflandırma katmanı, beyin tümörü veri setindeki sınıflara uygun şekilde özelleştirilmiştir.
- Giriş Katmanının Ayarlanması: Modelin giriş katmanı, 224×224 piksel boyutundaki görüntülerin modele doğrudan beslenmesini sağlayacak şekilde düzenlenmiştir. Bu ayar, DenseNet201'in varsayılan giriş boyutlarıyla uyumludur.

3.5. Denetimli Öğrenme Süreci

Bu çalışmada, denetimli öğrenme yöntemi, ESA modellerinin eğitimi sırasında uygulanmıştır. Denetimli öğrenme, veri örneklerinin doğru sınıf etiketleriyle birlikte modele sunulması ve modelin bu etiketleri tahmin etmeyi öğrenmesi temeline dayanan bir yapay zeka yaklaşımıdır. Bu çalışmada, her bir MRI görüntüsü, ilgili sınıf etiketiyle eşleştirilmiş ve model, bu etiketleri öğrenmek üzere optimize edilmiştir.

Çalışmada kullanılan veri kümesindeki MRI görüntüleri, dört farklı sınıfa ayrıldı. Her bir görüntü, veri kümesinde doğru sınıf etiketiyle ilişkilendirilmiştir. Örneğin, glioma sınıfına ait bir MRI görüntüsü, eğitim sürecinde “glioma” etiketiyle birlikte modele sunulmuştur. Mimariler, bu sınıflar için özel olarak yeniden yapılandırılmıştır ve model,

giriş görüntüleri ile etiketler arasındaki ilişkileri öğrenmek için optimize edilmiştir. Eğitim sürecinde, model her bir görüntü ve buna karşılık gelen etiket arasındaki ilişkiyi öğrenmek üzere bir optimizasyon algoritması kullanılmıştır. Optimizasyon işlemi sırasında, modelin tahminleri ve gerçek etiketler arasındaki hata, Momentumlu Stokastik Gradyan İnişi algoritması ile minimize edilmiştir. Bu süreçte modelin parametreleri sürekli olarak güncellenerek daha doğru tahminler yapabilmesi sağlanmıştır. Eğitimin ardından, model doğrulama ve test veri kümeleri üzerinde değerlendirilmiştir. Doğrulama veri kümesi, modelin hiperparametre ayarlarının optimize edilmesi ve aşırı öğrenmenin önlenmesi amacıyla kullanılmıştır. Test veri kümesi ise, modelin gerçek dünya senaryolarındaki performansını değerlendirmek için bağımsız bir ölçüt olarak kullanılmıştır.

Sonuç olarak mimariler, eğitim sürecinde doğru etiketlerle optimize edilmiştir ve giriş MRI görüntüleri ile sınıflar arasındaki ilişkileri başarılı bir şekilde öğrenmiştir. Doğrulama ve test süreçlerinde yapılan analizler, modelin genelleme yeteneğini ve eğitim sürecinin etkinliğini ortaya koymaktadır.

3.6. Pekiştirmeli Öğrenme ve Q-tablosu Oluşturma

Derin öğrenme modellerinin sınıflandırma tahminlerinin hassasiyetini arttırmak için Pekiştirmeli Öğrenme tabanlı bir Q-tablosu yöntemi uygulanmıştır. Q-tablosu, her bir tahmin edilen sınıf için yüzdelik olasılıkların hesaplanmasını sağlamıştır ve belirsizliklerin daha derinlemesine analiz edilmesine olanak tanımıştır. Bu yöntem, model tahminlerinin daha iyi yorumlanabilmesi ve karar süreçlerine yönelik daha zengin bir bilgi sunması amacıyla tercih edilmiştir.

Pekiştirmeli öğrenme süreci, aşağıdaki parametrelerle optimize edilmiştir:

- Durum Sayısı: 16
- Eylem Sayısı: 4 (veri setindeki sınıf sayısı)
- Öğrenme Oranı (α): 0.1
- Gelecek Ödül Etkisi (γ): 0.9
- Epsilon Başlangıç Değeri: 1.0 (keşif oranı)
- Minimum Epsilon: 0.01
- Epsilon Azalma Oranı: 0.99
- Episode Sayısı: 500
- Adım Sayısı: 10

Q-tablosu değerleri, modelin öğrenme süreci boyunca updateQTable fonksiyonu ile sürekli olarak güncellenmiştir. Bu süreçte, model her bir adımda belirli bir durum-eylem çifti için ödül aldı ve bu ödüller doğrultusunda Q-tablosu optimize edilmiştir. Pekiştirmeli öğrenme algoritması, her adımda keşif (exploration) ve sömürü

(exploitation) dengesini gözeterek, gelecekteki ödülleri maksimize edecek en iyi stratejiyi öğrenmiştir.

Eğitim sürecinin sonunda, Q-tablosu, her bir sınıf için yüzdelik olasılıklarla tahmin yapabilen bir yapı haline getirilmiştir. Eğitim kayıpları ve doğruluk oranları, öğrenme eğrileriyle gösterilmiştir. Ayrıca, Q-tablosu'nun ödül/ceza mekanizması sonrası güncellenmiş hali ısı haritası ile her üç mimarinin (VGG16, ResNet50, DenseNet201) performans karşılaştırmaları gerçekleştirilmiştir ve sonuçlar görselleştirilerek analiz edilmiştir. Oluşturulan grafiklerle kullanılan bir arayüz geliştirilmiştir. Bu sistem modellerin performans farklılıklarını açıkça göstermiştir ve model seçim sürecine önemli katkılar sağlamıştır.



4. BULGULAR

4.1. Veri Seti Oluşturma

Bu çalışmada kullanılan veri setleri glioma, meningioma, sağlıklı (no tumor) ve pituitary olmak üzere dört farklı beyin tümörü sınıfına ait MR görüntülerini içermektedir. Brain Tumor Dataset kaynağından temin edilen veri setleri, toplamda 7168 JPEG formatında görüntüden oluşmaktadır (Çizelge 4.1).

Veri setindeki MR görüntüleri, MATLAB ortamında derin öğrenme modellerine uygun hale getirilmiştir. Bu süreçte, tüm görüntüler 224×224 piksel boyutlarına ölçeklendirilmiş ve RGB formatında üç kanallı olarak işlenmiştir. Bu standartlaştırma işlemi, VGG16, ResNet50 ve DenseNet201 gibi derin öğrenme modellerinin varsayılan giriş boyutlarına uyum sağlamak için gerçekleştirilmiştir. Bu ön işleme adımları, görüntülerin modellenebilir bir yapıya dönüştürülmesine olanak tanıyarak sınıflandırma görevlerinde daha yüksek bir performans elde edilmesi sağlanmıştır.


Çizelge 4.1. Çalışmada kullanılan tümör çeşitleri ve sayıları

TÜMÖR TİPİ	GLIOMA	MENINGIOMA	PITUITARY	NO TUMOR
GÖRSEL SAYISI	1548	1362	1787	2471


Bu çalışmada kullanılan MR görüntüleri, modellerin eğitim ve değerlendirme süreçlerinde kullanılmak üzere üç temel grup olarak ayrılmıştır: Eğitim seti (%70), doğrulama seti (%15) ve test seti (%15) (Şekil 4.1) (Çizelge 4.2). Bu oranlar, veri setinin dengeli bir şekilde bölünmesini sağlamak ve modellerin bağımsız performanslarını doğru bir şekilde değerlendirebilmek amacıyla belirlenmiştir (Şekil 4.2).

Veri setinin bu gruplara ayrılması, MATLAB ortamında `splitEachLabel` fonksiyonu kullanılarak gerçekleştirilmiştir. Kullanılan kod:

```
[trainDs, valDs, testDs] = splitEachLabel(datastore, 0.7, 0.15, 0.15, 'randomized');
categoriesList = categories(trainDs.Labels)
```




Şekil 4.1. Veri setlerinin eğitim, test ve doğrulama olarak bölünmesi



Şekil 4.2. Tümör türleri, kendi içlerinde eğitim, doğrulama ve test kümeleri grafikleri

Çizelge 4.2. Her bir tümör türünün eğitim, doğrulama ve test olarak ayrımı

TÜMÖR TİPİ	GÖRSEL SAYISI	EĞİTİM	DOĞRULAMA	TEST
GLİOMA	1548	1084	232	232
MENİNGİOMA	1362	954	204	204
PİTÜİTARY	1787	1251	268	268
SAĞLIKLI (NO TUMOR)	2471	1729	371	371



Şekil 4.3. Ön işleme adımları sonrasında Mr görüntüsü. A) normal MR görüntüsü B) ön işlemleri adımları sonrasında işlenmiş MR görüntüsü (Muhammad Attique vd., 2012)

Veri setinin çeşitliliğini artırmak ve modellerin genelleme yeteneğini geliştirmek amacıyla veri artırma (data augmentation) teknikleri uygulanmıştır. Bu süreçte, rastgele döndürme (0° – 30° arasında), parlaklık değişimi (%80–%120 aralığında) ve yatay çevirme gibi yöntemler kullanılmıştır. Örneğin, bir glioma görüntüsü farklı açılarda döndürülmüş ve çeşitli parlaklık seviyelerinde işlenerek modele sunulmuştur (Şekil 4.3). Bu sayede, modelin görüntülerin farklı varyasyonlarını öğrenmesi sağlanmıştır ve eğitim sürecinde daha geniş bir örüntü yelpazesiyle çalışması mümkün olmuştur.

Veri seti hazırlandıktan sonra, VGG16, ResNet50 ve DenseNet201 modelleri, dört beyin tümörü sınıfını doğru bir şekilde sınıflandırmak amacıyla eğitilmiş ve optimize edilmiştir. Bu modellerin performansı, doğruluk, kesinlik, duyarlılık ve F1-skoru gibi çeşitli değerlendirme metrikleri kullanılarak analiz edilmiştir. Yapılan analizler, her bir modelin genel başarı düzeylerini karşılaştırma ve değerlendirme açısından değerli veriler sunmuştur. Bu süreç, modellerin sınıflandırma görevindeki etkinliğinin objektif bir şekilde ortaya konulmasına olanak tanımıştır.

4.2. Model Eğitimi

Bu çalışmada, beyin tümörü sınıflandırma problemi için derin öğrenme tabanlı ESA mimarilerinden VGG16, ResNet50 ve DenseNet201 modelleri kullanılmıştır. Modeller, transfer öğrenme yöntemiyle önceden eğitilmiş ImageNet ağırlıklarıyla başlatılmıştır. Glioma, meningioma, sağlıklı (no tumor) ve pituitary olmak üzere dört farklı sınıfı doğru şekilde sınıflandıracak şekilde özelleştirilmiştir.

Eğitim ve değerlendirme süreçlerinde, modellerin sınıflandırma etkinliklerini ölçmek için doğruluk, kesinlik, duyarlılık ve F1-skoru gibi performans hesaplamaları kullanılmıştır. Elde edilen sonuçlar, her bir modelin sınıflandırma görevindeki başarısını detaylı bir şekilde karşılaştırılmıştır ve değerlendirilmiştir. Bu kapsamlı analiz,

modellerin medikal görüntüleme alanında uygulanabilirliğini destekleyerek ileri çalışmalar için yol gösterici olmuştur.

VGG16 modeli, beyin tümörü sınıflarını doğru bir şekilde sınıflandırmak amacıyla eğitildi ve performansı MATLAB ortamında kapsamlı bir şekilde analiz edilmiştir. Eğitim sürecinin başlangıcında model, düşük bir doğruluk oranına sahipken, her bir epoch sonunda bu oranı hızlı bir şekilde artırmıştır. Eğitim toplamda 10 epoch ve 1560 iterasyon boyunca gerçekleştirilmiştir. Bu süreçte doğruluk ve kayıp eğrileri sürekli olarak izlenerek modelin performansı değerlendirilmiştir.


Modelin doğrulama setindeki performansı, %97,95 doğruluk oranı ve 0.97591 F1-skoru ile oldukça başarılı sonuçlar elde etmiştir. Bu yüksek performans, VGG16 modelinin beyin tümörü sınıflarını ayırt etme yetkinliğini açıkça ortaya koymuştur. Eğitim süreci boyunca kayıp değerleri, başlangıçta yaklaşık 2.5 seviyesindeyken iterasyonlar boyunca hızla azalarak minimum bir seviyeye ulaşmıştır. Eğitim ve doğrulama doğruluk eğrilerinin paralel bir şekilde ilerlemesi, modelin hem eğitim hem de doğrulama verilerinde tutarlı bir performans gösterdiğini ve aşırı öğrenme sergilemediğini kanıtlamıştır. Bu sonuçlar, VGG16 modelinin, beyin tümörü sınıflandırma görevinde yüksek doğruluk ve güvenilirlik sunduğunu ve bu tür medikal görüntüleme problemleri için etkili bir çözüm olduğunu göstermiştir (Şekil 4.4.).

Eğitim sürecinde, öğrenme oranı sabit bir şekilde 0.0001 olarak belirlenmiştir ve her 30 iterasyonda bir doğrulama verisi üzerinde modelin performansı değerlendirilmiştir. Bu düzenli değerlendirme, modelin öğrenme sürecinin izlenmesi ve performansının optimize edilmesi için kritik bir rol oynamaktadır. Eğitim tamamlandığında, doğruluk eğrisi sabit ve yüksek bir seviyede dengelendi, kayıp eğrisi ise azalmaya devam etmiştir. Bu durum, VGG16 modelinin sınıflandırma görevinde etkili bir öğrenme kapasitesine sahip olduğunu ve eğitim sürecinde verimli bir şekilde performans sergilediğini göstermiştir. Modelin hem doğruluk hem de kayıp eğrilerinde gözlenen bu olumlu eğilim, öğrenme sürecinin başarılı bir şekilde tamamlandığını ve modelin genel performansının tatmin edici düzeyde olduğunu kanıtlamıştır. Eğitim sürecinde, Momentumlu Stokastik Gradyan İnişi optimizasyon algoritması kullanılmış ve modelin performansını optimize etmek için aşağıdaki hiperparametreler belirlenmiştir:

- Mini-batch boyutu: 32
- Epoch sayısı: 10
- Başlangıç öğrenme oranı: 0.0001
- Doğrulama frekansı: Her 30 iterasyonda bir
- Karıştırma: Her epoch sonunda veri seti karıştırılarak modelin daha çeşitli bir veri dizisi üzerinde çalışması sağlanmıştır.

Eğitim sürecinin sonunda, modelin doğruluk eğrisi %97.95 seviyesine ulaşmıştır, kayıp eğrisi ise hızla azalarak minimum seviyede dengelenmiştir. Ayrıca, F1-skoru 0.97591 değerle, oldukça yüksek bir değere ulaşmıştı ve bu durum, modelin yalnızca yüksek doğruluk sağlamadığını, aynı zamanda sınıflandırma kalitesinde üstün bir performans sergilediğini açıkça ortaya koymuştur. Doğruluk ve kayıp eğrilerinin istikrarlı bir şekilde ilerlemesi, modelin hem eğitim hem de doğrulama verilerinde tutarlı bir performans sergilediğini kanıtlamıştır.

Sonuç olarak, VGG16 modeli, dört sınıfı yüksek doğruluk ve F1-skoru ile başarılı bir şekilde sınıflandırmayı başarmıştır. Doğrulama doğruluk oranının %97.95 ve F1-skorunun 0.97591 gibi yüksek seviyelere ulaşması, modelin güçlü bir genelleme yeteneğine sahip olduğunu göstermiştir. Bu sonuçlar, VGG16 modelinin beyin tümörü sınıflandırma görevindeki başarısını ve medikal görüntüleme alanındaki sınıflandırma problemleri için etkili bir çözüm sunduğunu desteklemiştir.



Şekil 4.4. VGG 16 sonuç grafiği

ResNet50 modeli, dört beyin tümörü sınıfını sınıflandırmak amacıyla eğitilmiş ve sonuçları detaylı bir şekilde analiz edilmiştir. Eğitim süreci MATLAB ortamında gerçekleştirilmiş olup, modelin performansı doğruluk ve kayıp eğrileri üzerinden değerlendirilmiştir.


Eğitim süreci boyunca model, başlangıçtan itibaren doğruluk oranını hızla artırmış ve kısa sürede stabil bir performans sergilemiştir (Şekil 4.5.). Eğitim, toplamda 10 epoch ve 1560 iterasyon boyunca sürdürülmüştür. Eğitim tamamlandığında, model doğrulama seti üzerinde %96.09 doğruluk oranı ve 0.95437 F1-skoru değerine ulaşmıştır.

Bu sonuçlar, ResNet50 modelinin beyin tümörü sınıflandırma görevinde yüksek doğruluk ve kalite sunduğunu açıkça ortaya koymuştur. Modelin kayıp eğrisi incelendiğinde, başlangıçta 1.6 seviyelerinde olan kayıp değerlerinin iterasyonlarla birlikte hızla azaldığı ve düşük bir seviyede sabitlendiği gözlemlenmiştir. Eğitim ve doğrulama kayıp eğrilerinin paralel bir seyir izlemesi, modelin istikrarlı bir öğrenme gerçekleştirdiğini ve aşırı öğrenme sergilemediğini ortaya koymuştur. Eğitim sürecinde sabit bir öğrenme oranı (0.0001) kullanıldı ve her 30 iterasyonda bir doğrulama değerlendirmesi gerçekleştirilmiştir. Eğitim doğruluk eğrisi, yaklaşık %96 seviyesine ulaşarak modelin genel performansının oldukça tutarlı olduğunu göstermiştir. Ayrıca, eğitim kayıplarının hızlı bir şekilde azalması ve stabil seviyelere ulaşması, modelin veriyi etkili bir şekilde öğrenebildiğini desteklemiştir.

Sonuç olarak, ResNet50 modeli, dört sınıfı başarılı bir şekilde sınıflandırmada yüksek doğruluk ve 0.95437 F1-skoru değerine ulaşmıştır. Bu sonuçlar, modelin beyin tümörü sınıflandırma probleminde etkili bir çözüm sunduğunu ve genelleme yeteneğinin güçlü olduğunu göstermiştir. ResNet50 modelinin eğitim süreci, Momentumlu Stokastik Gradyan İnişi optimizasyon algoritması ile gerçekleştirilmiş ve aşağıdaki hiperparametreler kullanılmıştır:

- Mini-batch boyutu: 32
- Epoch sayısı: 10
- Başlangıç öğrenme oranı: 0.0001
- Doğrulama frekansı: Her 30 iterasyonda bir
- Veri karıştırma: Her epoch sonunda veri seti karıştırıldı.

Eğitim süreci boyunca, ResNet50 modeli doğruluk eğrisini istikrarlı bir şekilde artırarak %96.09 seviyesine ulaşmıştır. Aynı zamanda, kayıp eğrisi hızla azalarak sabit bir seviyede dengelenmiştir. Elde edilen 0.95437 F1-skoru, modelin sınıflandırma performansının hem doğruluk hem de kalite açısından üstün olduğunu göstermiştir. Sonuç olarak, ResNet50 modeli, dört beyin tümörü sınıfını yüksek doğruluk ve F1-skoru ile başarıyla sınıflandırmıştır. Modelin doğrulama seti üzerinde elde ettiği %96.09 doğruluk oranı ve 0.95437 F1-skoru, bu mimarının de medikal görüntüleme alanında güvenilir bir çözüm sunduğunu ortaya koymuştur.



Şekil 4.5. ResNet50 sonuç grafiği


DenseNet201 modeli, beyin tümörü sınıflarını sınıflandırmak amacıyla eğitilmiş ve performansı kapsamlı bir şekilde değerlendirilmiştir. Modelin eğitim süreci, MATLAB ortamında 10 epoch ve toplam 1560 iterasyon boyunca yürütülmüş; doğruluk ve kayıp eğrileri temel alınarak analiz edilmiştir (Şekil 4.6.).

DenseNet201 modeli, hem eğitim hem de doğrulama verileri üzerinde istikrarlı bir performans sergilemiş ve %96.93 doğruluk ile 0.96342 F1-skoru değerine ulaşmıştır. Eğitim süreci boyunca, kayıp değerleri başlangıçta yüksek bir seviyeden başlamış ancak her iterasyonda düzenli bir şekilde azalarak minimum seviyeye ulaşmıştır. Bu sonuç, modelin veriyi etkili bir şekilde öğrenebildiğini ve parametrelerini optimize edebildiğini göstermiştir. Eğitim süreci boyunca, DenseNet201 modeli sabit bir öğrenme oranı (0.0001) ile optimize edilmiş ve her 30 iterasyonda bir doğrulama seti üzerinde performansı değerlendirilmiştir. Eğitim doğruluk eğrisi, %96.93 seviyesine ulaşarak doğrulama doğruluk eğrisiyle paralel bir ilerleme kaydetmiştir. Bu durum, modelin hem eğitim hem de doğrulama verileri üzerinde tutarlı bir performans sergilediğini göstermiştir. Kayıp eğrisi, başlangıçta 1.5 seviyelerinde başlamış ancak iterasyonlarla birlikte hızla azalarak düşük ve stabil bir seviyeye ulaşmıştır. Bu sonuç, modelin veriyi etkili bir şekilde öğrenebildiğini ve optimizasyon sürecinin başarılı bir şekilde gerçekleştirildiğini ortaya koymuştur. Eğitim sürecinde, Momentumlu Stokastik Gradyan İnişi optimizasyon algoritması ve aşağıdaki hiperparametreler kullanılmıştır:

- Mini-batch boyutu: 32
- Epoch sayısı: 10

- Başlangıç öğrenme oranı: 0.0001
- Doğrulama frekansı: Her 30 iterasyonda bir
- Karıştırma: Her epoch sonunda veri seti karıştırıldı.

Modelin doğruluk eğrisi, eğitim sürecinin sonunda %96.93 seviyesine ulaşmış, kayıp eğrisi ise hızla azalarak sabit bir seviyede dengelenmiştir. F1-skorunun 0.96342 gibi yüksek bir değere ulaşması, modelin sınıflandırma görevindeki performansının hem doğruluk hem de kalite açısından üstün olduğunu ortaya koymuştur. Ayrıca, eğitim ve doğrulama performansının paralel bir seyir izlemesi, modelin aşırı öğrenme göstermeden genelleme yapabildiğini ve farklı veri gruplarında tutarlı bir başarı sergilediğini açıkça doğrulamıştır.



Şekil 4.6. DenseNet201 eğitim sonucu

VGG16 modeli, elde ettiği %97.95 doğruluk ve 0.97591 F1-skoru ile sınıflandırma görevinde en yüksek performansı göstermiştir. Bu başarı, modelin güçlü bir özellik çıkarım kapasitesine sahip olduğunu kanıtlamıştır. Ancak, bu üstün performans, 561 dakikalık eğitim süresi ile diğer modellere kıyasla daha uzun bir eğitim süresi gerektirmiştir. Bu durum, modelin hesaplama açısından maliyetli olduğunu göstermiştir. Özellikle hesaplama sürelerinin kritik olduğu uygulamalarda, VGG16'nın yüksek doğruluk potansiyeli ile işlem süresi arasındaki dengenin dikkate alınması önem arz etmiştir.

ResNet50 modeli, daha kısa bir eğitim süresiyle (203 dakika) %96.09 doğruluk ve 0.95437 F1-skoru elde etmiştir. Bu model, derin yapısında artık bloklar kullanarak


öğrenme kapasitesini artırmış ve hızlı bir eğitim süreci sunmuştur. Ancak doğruluk ve F1-skoru açısından VGG16 ve DenseNet201'nin gerisinde kalmıştır (Çizelge 4.3.).

DenseNet201 modeli, %96.93 doğruluk ve 0.96342 F1-skoru ile hem yüksek sınıflandırma doğruluğu hem de tutarlı bir performans sunmuştur. Eğitim süresi ise 425 dakika olarak ölçülmüştür. Model, yoğun bağlantı yapısı sayesinde daha az parametreyle yüksek performans elde etmiş ve karmaşık sınıflandırma görevlerinde etkili bir çözüm sunmuştur.

Çizelge 4.3. Mimarilerin doğruluk değerleri, F1 skor değerleri ve öğrenme süreleri karşılaştırılması

ESA MİMARİSİ	DOĞRULUK DEĞERİ	F1 SKORU	SÜRE (DK)
VGG16	%97.95	0.97591	561
RESNET50	%96.09	0.95437	203
DENSENET201	%96.93	0.96342	425

Sınıflandırma modelleriyle elde edilen karışıklık matrisi, eğitim ve test için ayrı ayrı aşağıdaki şekillerde ifade edilmiştir (Şekil 4.7, 4.8, 4.9).



a)

	glioma	meningioma	notumor	pitiuitary
Gerçek Etiket				
glioma	1073	10		1
meningioma	5	936	3	9
notumor			1730	
pitiuitary		7	1	1243
	glioma	meningioma	notumor	pitiuitary
	Tahmin edilen etiket			

b)

Şekil 4.7. VGG-16 test (a) ve eğitim (b) karışıklık matrisleri

	glioma	meningioma	notumor	pitiuitary
Gerçek Etiket				
glioma	230	2		
meningioma	4	190	3	7
notumor			371	
pitiuitary		3	1	264
	glioma	meningioma	notumor	pitiuitary
	Tahmin edilen etiket			

a)

Gerçek Etiket	glioma	1064	19		1
	meningioma	10	913	12	18
	notumor			1730	
	pitiuitary		7	1	1243
		glioma	meningioma	notumor	pitiuitary
		Tahmin edilen etiket			

b)

Şekil 4.8. ResNet50 test (a) ve eğitim (b) karışıklık matrisleri

Gerçek Etiket	glioma	232			
	meningioma		198	3	3
	notumor			371	
	pitiuitary	1	1		266
		glioma	meningioma	notumor	pitiuitary
		Tahmin edilen etiket			

a)

Gelecek Ödül Etkisi (γ - gamma): Gamma değeri 0.9 olarak ayarlandı ve modelin uzun vadeli ödülleri dikkate almasını sağlanmıştır. Bu yaklaşım, modelin yalnızca anlık ödülleri değil, gelecekteki ödül beklentilerini de optimize etmesine olanak tanımıştır.

Epsilon Başlangıç Değeri: Başlangıçta epsilon değeri 1.0 olarak belirlenmiştir ve epsilon-greedy stratejisi kullanılmıştır. Bu strateji, modelin başlangıç aşamalarında keşif odaklı çalışmasını ve zamanla daha iyi eylemleri seçmesini sağlamıştır.


Minimum Epsilon (minEpsilon): Minimum epsilon değeri 0.01 olarak belirlenmiştir. Eğitim sürecinin sonunda, modelin yalnızca en iyi eylemleri tercih etmesi sağlanmıştır.

Epsilon Azalma Oranı (decayRate): Her adımda epsilon değeri %1 oranında (0.99 çarpanı ile) azaltılmıştır. Bu yöntem, modelin öğrenme sürecinde keşiften sömürüye (exploration to exploitation) geçişini dengelemiştir.


Episode Sayısı (numEpisodes): Eğitim süreci toplamda 500 bölüm (episode) boyunca sürdürülmüş ve her bölümde model, belirlenen ödül fonksiyonu doğrultusunda optimize edilmiştir.

Adım Sayısı (numSteps): Her bir bölüm için maksimum 10 adım belirlenmiştir. Bu sınırlama, modelin her durum için eylem seçimlerini sınırlı bir zaman diliminde gerçekleştirmesine olanak tanımıştır.


Tüm bu parametreler, Q-tablosu'nun etkili bir şekilde optimize edilmesini sağlamış ve modelin sınıflandırma sürecinde daha açıklayıcı ve güvenilir sonuçlar sunmasına olanak tanımıştır. Belirlenen hiperparametreler, özellikle epsilon-greedy stratejisi ile birlikte modelin öğrenme sürecindeki keşif ve sömürü dengesini başarıyla yönetmiştir. Q- tablosu ile yapılan tahminlerin karşılaştırılması;




Şekil 4.10. Glioma tahmin sonuçları



Şekil 4.11. Pituitary tahmin sonuçları



Şekil 4.12. Sağlıklı (No tumor) tahmin sonuçları



Şekil 4.13. Meningioma tahmin sonuçları

5. TARTIŞMA

Bu çalışmada, “glioma, meningioma, sağlıklı (no tumor) ve pituitary” sınıflarını içeren beyin tümörü sınıflandırma problemi üzerinde derin öğrenme ve pekiştirmeli öğrenme yöntemlerinin bir arada kullanıldığı kapsamlı bir yaklaşım sunulmuştur. Çalışma sonuçları, kullanılan derin öğrenme modellerinin (VGG16, ResNet50, DenseNet201) güçlü ve zayıf yönlerini ortaya koyarak, pekiştirmeli öğrenme tabanlı Q-tablosu yönteminin sınıflandırma sürecine sağladığı katkıları açık bir şekilde göstermiştir.

Literatürdeki diğer yöntemlerle karşılaştırıldığında, bu çalışma çeşitli yönlerden yenilikçi bir perspektif sağlamaktadır. Öncelikle, veri ön işleme aşamasında uygulanan segmentasyon ve boyutlandırma tekniklerinin, görüntü kalitesini artırmada önemli bir katkı sunduğu görülmüştür. Bu durum, literatürdeki benzer çalışmalarda da doğrulanmıştır (Eker & Duru, 2021). Örneğin, BraTS veri seti üzerinde gerçekleştirilen araştırmalar, segmentasyon işlemlerinin sınıflandırma modellerinin doğruluk ve duyarlılık metriklerini iyileştirmede kritik bir rol oynadığını göstermektedir. Bu çalışma, segmentasyonun yanı sıra boyutlandırma adımlarını da optimize ederek, modellerin giriş verilerinde daha etkili öğrenim gerçekleştirmesine olanak tanımıştır ve sınıflandırma performansını artırmıştır. Sachdeva vd. (2016) çalışmasında çok ölçekli derin öğrenme yaklaşımını üç tip tümörün otomatik segmentasyonunda ve sınıflandırılmasında %97.3 doğrulukla kullanmıştır. Model genelleştirilememiş, modelin doğrulaması sadece test veri kümesi üzerinde yapılmıştır (Sachdeva vd., 2016). Başka bir çalışmada, dört farklı beyin tümörü türünü sınıflandırmak amacıyla bir ESA modeli tasarlanmıştır. Çalışmada, tümörsüz, glioblastoma, sarkom ve metastaz kategorilerini içeren bir veri kümesi kullanılmıştır. Model, 64 piksel boyutunda görüntülerle eğitilmiş ve derin sinir ağı ile aşırı öğrenme önleme teknikleri uygulanarak %96.97 doğruluk oranına ulaşmıştır (Mohsen vd., 2018).

Bu çalışmada kullanılan VGG-16, ResNet-50 ve DenseNet201 modelleri, literatürde beyin tümörü sınıflandırma görevlerinde yüksek doğruluk oranlarıyla dikkat çekmektedir. Örneğin, derin evrişimli sinir ağı modelinden elde edilen sonuçlar, derin öğrenme modelinin füzyonunun çok sınıflı sınıflandırma probleminin doğruluğunu artırdığını göstermektedir. Model %97.77'ye kadar sınıflandırma doğruluğu sağlamaya çalışmaktadır (Patil ve Kirange, 2023). T1-ağırlıklı açık kaynaklı bir beyin tümörü veri seti kullanılarak gerçekleştirilen bir çalışmada, derin öğrenme tabanlı ultra-hafif bir sistem ile çok sınıflı beyin tümörü tespiti yapılmıştır (Qureshi ve ark., 2022). Beyin tümörlerinin sınıflandırılması amacıyla kullanılan evrişimsel sinir ağı modeli, VGG16 ve topluluk öğrenmesi yöntemleri uygulanmış olup, en yüksek doğruluk oranı %98.41 ile oluşturulan topluluk modeli tarafından elde edilmiştir (Younis ve ark., 2022). Ayrıca, beyin tümörü görüntülerinde çekişmeli üretici ağlar ile varyasyonel otokodlayıcıların

birleştirilmesi sonucunda ResNet sınıflandırıcısı kullanılarak yapılan sınıflandırma işleminde doğruluk oranı %96.25 olarak belirlenmiştir (Ahmad ve ark., 2022).

Mathivanan vd. (2024) çalışmasında kullanılan transfer öğrenimi tekniğiyle dört farklı transfer öğrenme mimarisi değerlendirilmiştir: ResNet152, VGG19, DenseNet169 ve MobileNetv3. Modeller, kıyaslama veritabanından alınan bir veri kümesi üzerinde eğitilmiş ve doğrulanmıştır. MobileNetv3, %99.75'lik en yüksek doğruluk oranına ulaşarak mevcut diğer yöntemlerden önemli ölçüde daha iyi performans göstermiştir (). Yeni bir ince ayar tekniği ve derin transfer öğrenme kullanan yeni bir beyin tümörü sınıflandırma yönteminde transfer öğrenme tabanlı sınıflandırma stratejisi, meningioma, glioma ve hipofiz bezi kökenli MRI beyin tümörlerini içeren Figshare veri kümesi üzerinde çeşitli senaryolar altında değerlendirilmiştir (Karim vd., 2023). Önerilen derin transfer öğrenme yaklaşımı, bir ESA mimarisi ve bir SVM sınıflandırıcı ile %99.35 doğruluk ve bir ResNet-50 mimarisi ve ince ayar parametreleri ile %99,61 doğruluk elde ederek umut verici sonuçlar ortaya koymaktadır (Karim vd., 2023). Deepak ve Ameer (2019) çalışmasında beyin MR görüntülerini kullanarak temel öznelikleri çıkarmak ve tümörleri %98 doğrulukla üç sınıfa ayırmak için önceden eğitilmiş bir derin CNN, GoogLeNet kullanmıştır (Deepak ve Ameer, 2019). Sultan vd. (2019) çalışmasında ise 3064 (glioma, meningioma ve hipofiz tümörleri) ve 516 (Grade II, Grade III ve Grade IV) beyin tıbbi taramasına sahip halka açık iki veri kümesini kullanarak CNN tabanlı bir derin öğrenme modeli önermiştir. Önerilen yöntem %96.13 ve %98.7 ile en iyi doğruluğa sahiptir (Sultan vd., 2019).

Çalışmamızda kullanılan modellerin farklı tümör türlerini sınıflandırmadaki başarısı, Louis vd. (2016) önerdiği Dünya Sağlık Örgütü sınıflandırması ile uyumlu olarak değerlendirilmiştir (Louis vd., 2016). Özellikle DenseNet201 modelimizin glioma, meningioma ve pitüiter adenom sınıflarını ayırt etmedeki doğruluk oranı, literatürde mevcut yöntemlere kıyasla rekabetçi bir performans sergilemiştir. Bu bulgu, DenseNet201'in derin öğrenme mimarisi sayesinde medikal görüntü analizinde etkili bir çözüm sunduğunu ortaya koymaktadır.

Çalışmada kullanılan veri seti boyutunun sınırlı olması, model performansını bir ölçüde etkilemiştir. Ancak, veri artırma (data augmentation) yöntemleri ile bu sınırlama büyük ölçüde aşılmış ve sınıflandırma başarımları önemli ölçüde artırılmıştır. Literatürde de belirtildiği gibi, daha büyük ve çeşitli veri setleriyle çalışan modellerin genellikle daha yüksek performans sergilediği bilinmektedir (Menze vd., 2015). Bu durum, veri seti boyutu ve çeşitliliğinin model performansı üzerindeki önemini bir kez daha vurgulamaktadır. Ayrıca küçük veri setleriyle çalışıldığında aşırı öğrenme problemlerinin yaygın olduğu bilinmektedir (Goodfellow vd., 2016). Bu çalışmada, veri artırma (data augmentation) tekniklerinin yanı sıra Q-öğrenme tabanlı bir mekanizma kullanılarak bu sorunun üstesinden gelinmiş ve modellerin genelleme yetenekleri artırılmıştır. Veri artırma teknikleri sayesinde modeller, daha geniş bir veri çeşitliliğini öğrenmiş ve aşırı uyum riskini minimize etmiştir.

Önerilen çerçeve, diğer son teknoloji çalışmalarla karşılaştırıldığında rekabetçi sonuçlar ortaya koymuştur. Q-öğrenme algoritması, bu çalışmada model doğruluğunu artırmak ve hata oranını minimize etmek amacıyla etkili bir optimizasyon aracı olarak kullanılmıştır. Literatürde Q-öğrenme'nin medikal görüntü analizinde nadiren kullanıldığı ancak önemli bir potansiyele sahip olduğu belirtilmektedir (Zhou vd., 2021). Çalışmamızda, Q-öğrenme tabanlı iyileştirme stratejisi, sınıflandırma doğruluğunu artırmada başarılı olmuş ve modelin öğrenme sürecine önemli katkılar sağlamıştır. Özellikle segmentasyon ve durum hesaplama işlemleri, modelin beyin MR görüntülerindeki tümör farklılıklarını daha iyi ayırt edebilmesine olanak tanımıştır. Bu bulgu, Q-öğrenme'nin medikal görüntü analizi bağlamında etkili bir destekleyici yöntem olduğunu göstermektedir. Fakat Q-öğrenme yönteminde, veri seti boyutunun sınırlı olması ve modellerin gerçek dünya verileri üzerinde test edilmemiş olması, sonuçların genelleştirilebilirliği açısından bir kısıtlama oluşturmaktadır. Gelecekteki çalışmalarda daha geniş veri setleri kullanılarak model performansının daha kapsamlı bir şekilde değerlendirilmesi, sonuçların genelleştirilebilirliğini artıracak ve bu alana katkı sağlayacaktır.

Çalışmada kullanılan üç derin öğrenme modeli arasında, sınıflandırma doğruluğu ve F1-skoru açısından yapılan değerlendirmeler sonucunda, VGG16'nın en yüksek doğruluk oranı (%97.95) ve F1-skoru (0.97591) ile en başarılı model olduğu tespit edilmiştir. Ancak, VGG16'nın 561 dakikalık eğitim süresi, hesaplama maliyetinin oldukça yüksek olduğunu ve özellikle büyük veri setleri ya da gerçek zamanlı uygulamalarda kullanımının sınırlı olabileceğini ortaya koymaktadır. Literatürde de benzer şekilde, VGG tabanlı modellerin yüksek doğruluk oranları sunduğu, ancak bu başarıyı yüksek hesaplama gereksinimleri ile elde ettiği belirtilmiştir. Bu durum, hesaplama gücünün sınırlı olduğu ortamlarda daha optimize edilmiş modellerin tercih edilmesi gerekliliğini ortaya koymaktadır.

ResNet50 modeli, %96.09 doğruluk oranı ve 0.95437 F1-skoru ile dikkat çekici bir performans sergilemiş ve hızlı bir eğitim süreci (203 dakika) sayesinde, daha kısa sürede sonuç alınması gereken uygulamalar için uygun bir çözüm sunmuştur. Modelin artık blok yapısı, derin katmanlarda öğrenmeyi kolaylaştırarak verimli bir yapı sağlamıştır. Ancak, elde edilen sonuçlar, doğruluk ve F1-skoru açısından ResNet50'nin VGG16 ve DenseNet201 modellerinin gerisinde kaldığını göstermektedir. Bu durum, ResNet50'nin karmaşık örüntüleri öğrenme kapasitesinin sınırlı olabileceğini ve bu gibi durumlarda daha derin veya optimize edilmiş modellerin tercih edilmesi gerektiğini düşündürmektedir.

DenseNet201 modeli, %96.93 doğruluk oranı ve 0.96342 F1-skoru ile hem doğruluk hem de sınıflandırma kalitesinde dengeli bir performans sergilemiştir. Eğitim süresi açısından da 425 dakikalık bir süreyle makul bir zaman diliminde tamamlanmıştır. Modelin yoğun bağlantı yapısı, her katmanın önceki tüm katmanlardan bilgi almasını

sağlayarak bilgi paylaşımını artırmış ve verimli bir öğrenme süreci sunmuştur. Bu özellik, modelin genelleme yeteneğini artırarak dengeli bir çözüm sunduğunu göstermektedir.

Bu çalışmanın yenilikçi yönlerinden biri, Q-tablosu tabanlı pekiştirmeli öğrenme yönteminin sınıflandırma sürecine entegre edilmesidir. Q-tablosu, modelin sınıf tahminlerini yüzdelik olasılıklarla ifade ederek sınıflandırma sonuçlarının daha açıklayıcı hale gelmesini sağlamıştır. Örneğin, bir glioma görüntüsü için sınıflar arasındaki yüzdelik tahminler, yalnızca sınıf tahminlerinin güvenilirliğini değerlendirmekle kalmamış, aynı zamanda belirsizliklerin analiz edilmesine de olanak tanımıştır. Bu yaklaşım, özellikle tıbbi uzmanların teşhis kararlarını desteklemek açısından büyük bir avantaj sunmaktadır. Bununla birlikte, Q-tablosu yönteminin sınıflandırma sürecinde kullanılan hiperparametrelerin seçimi, model performansı üzerinde önemli bir etkiye sahiptir. Çalışmada kullanılan epsilon-greedy stratejisi, başlangıçta keşif ağırlıklı bir öğrenme süreci sağlarken, eğitim ilerledikçe daha optimal eylemlerin seçilmesini kolaylaştırmıştır. Ancak, epsilon değerinin azalma oranı (decay rate) gibi hiperparametrelerin farklı ayarlarının incelenmesi, modelin performansını daha da iyileştirebilir.

Çalışmanın bazı sınırlamaları da bulunmaktadır. Öncelikle, veri seti yalnızca dört sınıf içermekte olup, toplam veri boyutu sınırlıdır. Her sınıf için dengeli örnek sayısı sağlanmış olsa da, daha büyük ve çeşitli veri setlerinin kullanılması, modellerin performansının daha kapsamlı bir şekilde değerlendirilmesine olanak tanıyabilir. Ayrıca, eğitim süreci sırasında yalnızca bir CPU donanımı kullanılmıştır. GPU veya TPU gibi daha hızlı hesaplama kaynaklarının kullanılması, modelin eğitim süresini önemli ölçüde kısaltabilir. Bir diğer sınırlama, Q-tablosu yönteminin yalnızca dört sınıf için uygulanmış olmasıdır. Daha fazla sınıf içeren veri setlerinde Q-tablosu yönteminin ölçeklenebilirliği ve performansının değerlendirilmesi gerekmektedir. Ayrıca, Politika Gradyenleri gibi farklı pekiştirmeli öğrenme algoritmalarının Q-tablosu yöntemiyle karşılaştırılması, gelecekteki çalışmalarda ele alınabilecek önemli araştırma konularından biridir.

Bu çalışmada elde edilen sonuçlar, gelecekteki çalışmalara yönelik birkaç önemli araştırma önerisini beraberinde getirmektedir. Model tahminlerinin açıklayıcı sonuçlar sunması için Q-tablosu'na ek olarak açıklanabilir yapay zeka teknikleri entegre edilebilir.

6. SONUÇLAR

Bu çalışmada, beyin tümörü sınıflandırma problemi üzerinde üç farklı ESA mimarisi (VGG16, ResNet50, DenseNet201) kullanılarak detaylı bir analiz gerçekleştirilmiştir. Amacımız, “glioma, meningioma, sağlıklı (no tumor), ve pituitary” sınıflarına ait MRI görüntülerini başarıyla sınıflandırmak ve bu sınıflandırma işlemi daha açıklayıcı hale getirmek için pekiştirmeli öğrenme tabanlı bir Q-tablosu yöntemi geliştirmek olmuştur. Bu kapsamda, eğitim ve değerlendirme süreçlerinde kullanılan yöntemler, modellerin performansları ve elde edilen sonuçlar aşağıda detaylı bir şekilde açıklanmıştır.

Bu çalışmada kullanılan veri seti, dört farklı sınıfı temsil eden MRI görüntülerinden oluşmakta olup, MATLAB ortamında splitEachLabel fonksiyonu ile eğitim (%70), doğrulama (%15) ve test (%15) olarak üç gruba ayrılmıştır. Görüntüler, derin öğrenme modellerinin gerektirdiği şekilde 224×224 piksel boyutuna ölçeklendirilmiştir. Çalışmada VGG16, ResNet50 ve DenseNet201 olmak üzere üç farklı ESA mimarisi kullanılarak modellerin doğruluk, F1-skoru ve eğitim süresi açısından performansları değerlendirilmiştir. VGG16 modeli %97.95 doğruluk ve 0.97591 F1-skoru ile en yüksek sınıflandırma başarısını göstermiş ancak 561 dakikalık uzun eğitim süresiyle dikkat çekmiştir. ResNet50 modeli, 203 dakika gibi kısa bir sürede eğitilerek en hızlı model olmasına rağmen %96.09 doğruluk ve 0.95437 F1-skoru ile diğer modellere kıyasla daha düşük bir performans sergilemiştir. DenseNet201 modeli ise %96.93 doğruluk, 0.96342 F1-skoru ve 425 dakikalık eğitim süresiyle hem yüksek başarı hem de dengeli bir eğitim süresi sunarak etkili bir çözüm olduğunu göstermiştir.

Modellerin tahminlerini daha açıklayıcı hale getirmek amacıyla, pekiştirmeli öğrenme tabanlı Q-tablosu yöntemi geliştirilmiştir. updateQTable fonksiyonu ile her adımda güncellenen bu yöntem, öğrenmeyi arttırmış ve tahminlerin yüzdelerle olasılıklarla ifade edilmesini sağlamıştır. Örneğin, bir glioma görüntüsü için %88 glioma, %7 meningioma, %3 sağlıklı (no tumor), %2 pituitary olarak hesaplanmıştır. Bu yöntem, model tahminlerinin sadece doğruluğunu değil, aynı zamanda sınıflar arasındaki belirsizlikleri de değerlendirme imkanı sunarak sınıflandırma sonuçlarını daha anlaşılır hale getirmiştir.

Çalışmadan elde edilen bulgular, derin öğrenme modellerinin, beyin tümörü sınıflandırma gibi karmaşık medikal görüntüleme problemleri için etkili bir çözüm sunduğunu göstermektedir. Bunun yanı sıra, Q-tablosu gibi pekiştirmeli öğrenme yöntemlerinin sınıflandırma süreçlerine entegre edilmesi, tahmin sonuçlarının hem doğruluğunu hem de anlaşılabilirliğini artırmıştır. Bu yöntemler, sadece sınıflandırma performansını iyileştirmekle kalmamış, aynı zamanda sonuçların tıbbi uzmanlar tarafından daha kolay yorumlanmasına da katkı sağlamıştır.

Sonuç olarak, bu çalışma, derin öğrenme ile pekiştirmeli öğrenmenin entegre bir şekilde uygulanarak, medikal görüntüleme alanında güvenilir ve açıklayıcı teşhis destek

sistemlerinin geliştirilmesine katkı sağladığını ortaya koymuştur. VGG16, ResNet50 ve DenseNet201 modelleri ile Q-tablosu yönteminin birlikte kullanımı, hem sınıflandırma doğruluğunu hem de tahmin sonuçlarının kararlılığını güçlendirmiştir. Ayrıca tanının hızlı olabilmesi için sisteme bir arayüz tasarlanmıştır. Böylelikle süreç daha ergonomik hale getirilmiştir. Tüm bu sistemin, medikal alanda kullanılabilirliği ve benzer sınıflandırma problemleri için uygulanabilirliği önemli bir potansiyele sahiptir.



7. KAYNAKLAR

- 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.
- Abu-Jamie, T. N., & Abu-Naser, S. S. (2022). Classification of sign-language using VGG16. *International Journal of Academic and Applied Research (IJAAR)*, 6(4), 94-100.
- Aggarwal, C. C., Aggarwal, L. F., & Lagerstrom-Fife. (2020). *Linear algebra and optimization for machine learning* (Vol. 156). Cham: Springer International Publishing.
- Ahmad, B., Sun, J., You, Q., Palade, V., & Mao, Z. (2022). Brain tumor classification using a combination of variational autoencoders and generative adversarial networks. *Biomedicines*, 10(2), 223.
- Al-Shehari, T., & Alsowail, R. A. (2021). An insider data leakage detection using one-hot encoding, synthetic minority oversampling and machine learning techniques. *Entropy*, 23(10), 1258.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., ... & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8, 1-74.
- Aswathy, S. U., Dhas, G. G. D., & Kumar, S. S. (2014, July). A survey on detection of brain tumor from MRI brain images. In 2014 international conference on control, Instrumentation, Communication and Computational Technologies (ICCICCT) (pp. 871-877). IEEE.
- Attique, M., Gilanie, G., Mehmood, M. S., Naweed, M. S., Ikram, M., Kamran, J. A., & Vitkin, A. (2012). Colorization and automated segmentation of human T2 MR brain images for characterization of soft tissues. *PloS one*, 7(3), e33616.
- Barto, A. G. (2021). *Reinforcement Learning: An Introduction*. By Richard's Sutton. *SIAM Rev*, 6(2), 423.
- 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.
- Benjamins, S., Dhunoo, P., & Meskó, B. (2020). The state of artificial intelligence-based FDA-approved medical devices and algorithms: an online database. *NPJ digital medicine*, 3(1), 118.
- Biemer, P.P. & Lyberg, L. (2003) Errors due to interviewers and interviewing. In: *Introduction to survey quality*. ch. 5, New York, NY: Wiley, pp. 149–187.
- Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.

- Boas, F. E., & Fleischmann, D. (2012). CT artifacts: causes and reduction techniques. *Imaging Med*, 4(2), 229-240.
- Bogomolny, D. L., Petrovich, N. M., Hou, B. L., Peck, K. K., Kim, M. J., & Holodny, A. I. (2004). Functional MRI in the brain tumor patient. *Topics in Magnetic Resonance Imaging*, 15(5), 325-335.
- Braiek, H. B., & Khomh, F. (2020). On testing machine learning programs. *Journal of Systems and Software*, 164, 110542.
- Brat, D. J., Aldape, K., Colman, H., Holland, E. C., Louis, D. N., Jenkins, R. B., ... Wesseling, P. (2018). cIMPACT-NOW update 3: Recommended diagnostic criteria for “Diffuse astrocytic glioma, IDH-wildtype, with molecular features of glioblastoma, WHO grade IV.” *Acta Neuropathologica*, 136(5), 805–810.
- Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R. L., Torre, L. A., & Jemal, A. (2018). Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: a cancer journal for clinicians*, 68(6), 394-424.
- Charbuty, B., & Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(01), 20-28.
- Chen, M., Challita, U., Saad, W., Yin, C., & Debbah, M. (2017). Machine learning for wireless networks with artificial intelligence: A tutorial on neural networks. *arXiv preprint arXiv:1710.02913*, 9.
- Chen, W. (2007). Clinical applications of PET in brain tumors. *Journal of nuclear medicine*, 48(9), 1468-1481.
- Cheng, J., Yang, W., Huang, M., Huang, W., Jiang, J., Zhou, Y., ... & Chen, W. (2016). Retrieval of brain tumors by adaptive spatial pooling and fisher vector representation. *PloS one*, 11(6), e0157112.
- Chollet, F., & Chollet, F. (2021). Deep learning with Python. *simon and schuster*.
- Christodoulou, E., Ma, J., Collins, G. S., Steyerberg, E. W., Verbakel, J. Y., & Van Calster, B. (2019). A systematic review shows no performance benefit of machine learning over logistic regression for clinical prediction models. *Journal of clinical epidemiology*, 110, 12-22.
- Cihan, P. (2018). Determination of diagnosis, prognosis and risk factors in animal diseases using by data mining methods (Doctoral dissertation, PhD Thesis, Yildiz Technical University, Istanbul, Turkey).
- Dale, B. M., Brown, M. A., & Semelka, R. C. (2015). MRI: basic principles and applications. John Wiley & Sons.
- 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(8), 8357-8369.

- Demirel, C., & Soylu, E. (2024). MRI Verilerinde Tümör Tespiti için Transfer Tabanlı Derin Öğrenme Algoritması Karşılaştırması. *Karadeniz Fen Bilimleri Dergisi*, 14(3), 1322-1339.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009, June). Imagenet: A large-scale hierarchical image database. In 2009 IEEE conference on computer vision and pattern recognition (pp. 248-255). Ieee.
- Doan, B. T., Meme, S., & Beloeil, J. C. (2013). General principles of MRI. *The Chemistry of Contrast Agents in Medical Magnetic Resonance Imaging*, 1-23.
- Doan, T., & Kalita, J. (2015, November). Selecting machine learning algorithms using regression models. In 2015 IEEE International Conference on Data Mining Workshop (ICDMW) (pp. 1498-1505). IEEE.
- Dong, H., Dong, H., Ding, Z., Zhang, S., & Chang, T. (2020). *Deep Reinforcement Learning*. Singapore: Springer Singapore.
- Eker, A. G., & Duru, N. (2021). Medikal görüntü işlemede derin öğrenme uygulamaları. *Acta Infologica*, 5(2), 459-474.
- El Naqa, I., & Murphy, M. J. (2015). *What is machine learning?* (pp. 3-11). Springer International Publishing.
- Enders, C. K. (2022). *Applied missing data analysis* (2nd ed.). Guilford Publications.
- Erickson, B. J., & Kitamura, F. (2021). Magician's corner: 9. Performance metrics for machine learning models. *Radiology: Artificial Intelligence*, 3(3), e200126.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *nature*, 542(7639), 115-118.
- Fayaz, S. A., Jahangeer Sidiq, S., Zaman, M., & Butt, M. A. (2022). *Machine learning: An introduction to reinforcement learning*. Machine Learning and Data Science: Fundamentals and Applications, 1-22.
- García-Laencina, P. J., Sancho-Gómez, J. L., & Figueiras-Vidal, A. R. (2010). Pattern classification with missing data: a review. *Neural Computing and Applications*, 19, 263-282.
- Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems* (3rd ed.). O'Reilly Media.
- Ghavamzadeh, M., Mannor, S., Pineau, J., & Tamar, A. (2015). Bayesian reinforcement learning: A survey. *Foundations and Trends® in Machine Learning*, 8(5-6), 359-483.
- Ghosal, P., Nandanwar, L., Kanchan, S., Bhadra, A., Chakraborty, J., & Nandi, D. (2019, February). Brain tumor classification using ResNet-101 based squeeze and excitation deep neural network. In 2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP) (pp. 1-6). IEEE.

- Glez-Peña, D., Lourenço, A., López-Fernández, H., Reboiro-Jato, M., & Fdez-Riverola, F. (2014). Web scraping technologies in an API world. *Briefings in bioinformatics*, 15(5), 788-797.
- Goodenberger, M. L., & Jenkins, R. B. (2012). Genetics of adult glioma. *Cancer Genetics*, 205(12), 613-621.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Convolutional networks. *Deep learning*, 2016, 330-372.
- Gordillo, N., Montseny, E., & Sobrevilla, P. (2013). State of the art survey on MRI brain tumor segmentation. *Magnetic resonance imaging*, 31(8), 1426-1438.
- Grochans, S., Cybulska, A. M., Simińska, D., Korbecki, J., Kojder, K., Chlubek, D., & Baranowska-Bosiacka, I. (2022). Epidemiology of glioblastoma multiforme—literature review. *Cancers*, 14(10), 2412.
- Gubbi, J., Buyya, R., Marusic, S., & Palaniswami, M. (2013). Internet of Things (IoT): A vision, architectural elements, and future directions. *Future generation computer systems*, 29(7), 1645-1660.
- Gupta, J., Pathak, S., & Kumar, G. (2022, May). Deep learning (CNN) and transfer learning: a review. In *Journal of Physics: Conference Series* (Vol. 2273, No. 1, p. 012029). IOP Publishing.
- Hahne, F., Huber, W., Gentleman, R., Falcon, S., Gentleman, R., & Carey, V. J. (2008). Unsupervised machine learning. *Bioconductor case studies*, 137-157.
- Hammad, I., & El-Sankary, K. (2018). Impact of approximate multipliers on VGG deep learning network. *IEEE Access*, 6, 60438-60444.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques*, Waltham: Morgan Kaufmann Publishers.
- Hashemi, R. H., Bradley, W. G., & Lisanti, C. J. (2017). *MRI: The basics* (4th ed.). Lippincott Williams & Wilkins.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Identity mappings in deep residual networks. In *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV* 14 (pp. 630-645). Springer International Publishing.
- Hemetsberger, A. (2013). Crowdsourcing. In *The Routledge companion to digital consumption* (pp. 159-170). Routledge.
- Holdsworth, S. J., & Bammer, R. (2008, September). Magnetic resonance imaging techniques: fMRI, DWI, and PWI. In *Seminars in neurology* (Vol. 28, No. 04, pp. 395-406). © Thieme Medical Publishers.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).

- Idiculla, P. S., Gurala, D., Palanisamy, M., Vijayakumar, R., Dhandapani, S., & Nagarajan, E. (2020). Cerebral venous thrombosis: a comprehensive review. *European neurology*, 83(4), 369-379.
- Jain, R. (2011). Perfusion CT imaging of brain tumors: an overview. *American Journal of Neuroradiology*, 32(9), 1570-1577.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning (Vol. 112, p. 18). New York: springer.
- Johnson, C. L., Dohrmann, S. M., Burt, V. L., & Mohadjer, L. K. (2014). National health and nutrition examination survey: sample design, 2011-2014 (No. 2014). US Department of Health and Human Services, Centers for Disease Control and Prevention, National Center for Health Statistics.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260
- K. He, X. Zhang, S. Ren, J. Sun Deep residual learning for image recognition IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (2016), pp. 770-778.
- Kan, P., Liu, J. K., Hedlund, G., Brockmeyer, D. L., Walker, M. L., & Kestle, J. R. (2006). The role of diffusion-weighted magnetic resonance imaging in pediatric brain tumors. *Child's Nervous System*, 22, 1435-1439.
- Karim, P. J., Mahmood, S. R. & Sah, M. Brain tumor classification using fine-tuning based deep transfer learning and support vector machine. *Int. J. Comput. Digit. Syst.* 13(1), 84–96 (2023).
- Kelleher, J. D. (2019). Deep learning. MIT press.
- Kılıçarslan, S., Adem, K., & Çelik, M. (2021). An overview of the activation functions used in deep learning algorithms. *Journal of New Results in Science*, 10(3), 75-88.
- Kotsiantis, S., Kanellopoulos, D., & Pintelas, P. (2006). Handling imbalanced datasets: A review. *GESTS international transactions on computer science and engineering*, 30(1), 25-36.
- Kraff, O., Fischer, A., Nagel, A. M., Mönninghoff, C., & Ladd, M. E. (2015). MRI at 7 Tesla and above: demonstrated and potential capabilities. *Journal of Magnetic Resonance Imaging*, 41(1), 13-33.
- Krishnapriya, S., & Karuna, Y. (2023). Pre-trained deep learning models for brain MRI image classification. *Frontiers in Human Neuroscience*, 17, 1150120.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Krotov, V., Johnson, L., & Silva, L. (2020). Tutorial: Legality and ethics of web scraping.
- Kuhn, M., & Johnson, K. (2013). Applied predictive modeling (Vol. 26, p. 13). Springer.

- Kulkarni, P. (2012). Reinforcement and systemic machine learning for decision making (Vol. 1). John Wiley & Sons.
- Langseth, H., & Nielsen, T. D. (2006). Classification using hierarchical naive bayes models. *Machine learning*, 63, 135-159.
- Larson, P. E., Han, M., Krug, R., Jakary, A., Nelson, S. J., Vigneron, D. B., ... & Kelley, D. A. (2016). Ultrashort echo time and zero echo time MRI at 7T. *Magnetic Resonance Materials in Physics, Biology and Medicine*, 29, 359-370.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Leitão, D., Teixeira, R. P. A., Price, A., Uus, A., Hajnal, J. V., & Malik, S. J. (2021). Efficiency analysis for quantitative MRI of T1 and T2 relaxometry methods. *Physics in Medicine & Biology*, 66(15), 15NT02.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- Louis, D. N., Aldape, K., Brat, D. J., Capper, D., Ellison, D. W., Hawkins, C., ... & von Deimling, A. (2016). cIMPACT-NOW (the consortium to inform molecular and practical approaches to CNS tumor taxonomy): a new initiative in advancing nervous system tumor classification. *Brain pathology*, 27(6), 851.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*, 9(1), 381-386.
- Mandel, J. (2012). The statistical analysis of experimental data. Courier Corporation.
- Marr, B. (2021). Data strategy: How to profit from a world of big data, analytics and artificial intelligence. Kogan Page Publishers.
- Mascarenhas, S., & Agarwal, M. (2021, November). A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification. In 2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON) (Vol. 1, pp. 96-99). IEEE.
- Mathivanan, S. K., Sonaimuthu, S., Murugesan, S., Rajadurai, H., Shivahare, B. D., & Shah, M. A. (2024). Employing deep learning and transfer learning for accurate brain tumor detection. *Scientific Reports*, 14(1), 7232.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-12.
- Menze, B. H., Jakab, A., Bauer, S., Kalpathy-Cramer, J., Farahani, K., Kirby, J., ... & Van Leemput, K. (2015). The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). *IEEE Transactions on Medical Imaging*, 34(10), 1993-2024.

- 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.
- Mitchell, R. (2018). *Web scraping with Python: Collecting more data from the modern web*. O'Reilly Media.
- Mittal, K., Gill, K. S., Malhotra, S., & Devliyal, S. (2024, April). Evolving Diagnostic Techniques for Speech Disorders: Investigating Dysarthria Classification Through DenseNet201 CNN Framework. In *2024 International Conference on Communication, Computing and Internet of Things (IC3IoT)* (pp. 1-6). IEEE.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *nature*, 518(7540), 529-533.
- Mohsen, H., El-Dahshan, E.-S. A., El-Horbaty, E.-S. M., & Salem, A.-B. M. (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68–71.
- Molinaro, A. M., Taylor, J. W., Wiencke, J. K., & Wrensch, M. R. (2019). Genetic and molecular epidemiology of adult diffuse glioma. *Nature Reviews Neurology*, 15(7), 405-417.
- Moor, J. H. (2001). The status and future of the Turing test. *Minds and Machines*, 11, 77-93.
- Mousavi, S. S., Schukat, M., & Howley, E. (2018). Deep reinforcement learning: an overview. In *Proceedings of SAI Intelligent Systems Conference (IntelliSys) 2016: Volume 2* (pp. 426-440). Springer International Publishing.
- Murphy, E. A., Ehrhardt, B., Gregson, C. L., von Arx, O. A., Hartley, A., Whitehouse, M. R., ... & Gill, H. S. (2022). Machine learning outperforms clinical experts in classification of hip fractures. *Scientific reports*, 12(1), 2058.
- Naeem, S., Ali, A., Anam, S., & Ahmed, M. M. (2023). An unsupervised machine learning algorithms: Comprehensive review. *International Journal of Computing and Digital Systems*.
- Nancy, A. M., & Maheswari, R. (2025). Brain tumor segmentation and classification using transfer learning based CNN model with model agnostic concept interpretation. *Multimedia Tools and Applications*, 84(5), 2509-2538.
- Narayanan, A., & Shmatikov, V. (2008, May). Robust de-anonymization of large sparse datasets. In *2008 IEEE Symposium on Security and Privacy (sp 2008)* (pp. 111-125). IEEE.
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons*, 4(51-62), 56.
- Nielsen, J. D., Madsen, K. H., Puonti, O., Siebner, H. R., Bauer, C., Madsen, C. G., ... & Thielscher, A. (2018). Automatic skull segmentation from MR images for realistic volume conductor models of the head: Assessment of the state-of-the-art. *Neuroimage*, 174, 587-598.

- Nilsson, N. J. (2009). The quest for artificial intelligence. Cambridge University Press.
- Novaković, J. D., Veljović, A., Ilić, S. S., Papić, Ž., & Tomović, M. (2017). Evaluation of classification models in machine learning. *Theory and Applications of Mathematics & Computer Science*, 7(1), 39.
- Ostrom, Q. T., Gittleman, H., Farah, P., Ondracek, A., Chen, Y., Wolinsky, Y., Stroup, N. E., Kruchko, C., & Barnholtz-Sloan, J. S. (2014). CBTRUS statistical report: Primary brain and central nervous system tumors diagnosed in the United States in 2006–2010. *Neuro-Oncology*, 15(Suppl. 2), ii1–ii56.
- Patel, B. K., Hilal, T., Covington, M., Zhang, N., Kosiorek, H. E., Lobbes, M., ... & Pockaj, B. A. (2018). Contrast-enhanced spectral mammography is comparable to MRI in the assessment of residual breast cancer following neoadjuvant systemic therapy. *Annals of surgical oncology*, 25, 1350-1356.
- Patil, S., & Kirange, D. (2023). Ensemble of deep learning models for brain tumor detection. *Procedia Computer Science*, 218, 2468-2479.
- Qureshi, S. A., Raza, S. E. A., Hussain, L., Malibari, A. A., Nour, M. K., Rehman, A. U., ... & Hilal, A. M. (2022). Intelligent ultra-light deep learning model for multi-class brain tumor detection. *Applied Sciences*, 12(8), 3715.
- Rácz, A., Bajusz, D., & Héberger, K. (2019). Multi-level comparison of machine learning classifiers and their performance metrics. *Molecules*, 24(15), 2811.
- Rahman, M. A., Masum, M. I., Hasib, K. M., Mridha, M. F., Alfarhood, S., Safran, M., & Che, D. (2024). GliomaCNN: An effective lightweight CNN model in assessment of classifying brain tumor from magnetic resonance images using explainable AI. *Computer Modeling in Engineering & Sciences*, 140(3), 2425.
- Rajpurkar, P., Chen, E., Banerjee, O., & Topol, E. J. (2022). AI in health and medicine. *Nature medicine*, 28(1), 31-38.
- Rasool, M., Ismail, N. A., Boulila, W., Ammar, A., Samma, H., Yafooz, W. M., & Emara, A. H. M. (2022). A hybrid deep learning model for brain tumour classification. *Entropy*, 24(6), 799.
- Rathinam, V., Sasireka, R., & Valarmathi, K. (2024). An Adaptive Fuzzy C-Means segmentation and deep learning model for efficient mammogram classification using VGG-Net. *Biomedical Signal Processing and Control*, 88, 105617.
- Ray, S. (2019, February). A quick review of machine learning algorithms. In 2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon) (pp. 35-39). IEEE.
- Rehman, A., Khan, M. A., Saba, T., Mehmood, Z., Tariq, U., & Ayesha, N. (2021). Microscopic brain tumor detection and classification using 3D CNN and feature selection architecture. *Microscopy Research and Technique*, 84(1), 133-149.
- Rehman, A., Naz, S., Razzak, M. I., Akram, F., & Imran, M. (2020). A deep learning-based framework for automatic brain tumors classification using transfer learning. *Circuits, Systems, and Signal Processing*, 39(2), 757-775.

- Ren, Q., Cheng, H., & Han, H. (2017, March). Research on machine learning framework based on random forest algorithm. In AIP conference proceedings (Vol. 1820, No. 1). AIP Publishing.
- Ren, W., Yu, Y., Zhang, J., & Huang, K. (2014, August). Learning convolutional nonlinear features for k nearest neighbor image classification. In 2014 22nd international conference on pattern recognition (pp. 4358-4363). IEEE.
- Rusk, N. (2016). Deep learning. *Nature Methods*, 13(1), 35-35.
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Rydelius, A. (2023). Brain Tumor Imaging and Treatment Effects. Imaging findings and cognitive function in glioblastoma patients (No. 2023: 68). Lund University.
- Sachdeva J, Kumar V, Gupta I, Khandelwal N, Ahuja CK. A package-SFERCB-“Segmentation, feature extraction, reduction and classification analysis by both SVM and ANN for brain tumors.” *Applied Soft Computing* 2016; 47:151–67.
- Sangeetha, R., Mohanarathinam, A., Aravindh, G., Jayachitra, S., & Bhuvaneswari, M. (2020, November). Automatic detection of brain tumor using deep learning algorithms. In 2020 4th International Conference on Electronics, Communication and Aerospace Technology (ICECA) (pp. 1-4). IEEE.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview.
- Schwartz, H. M. (2014). *Multi-agent machine learning: A reinforcement approach*. John Wiley & Sons.
- Seber, G. A., & Lee, A. J. (2012). *Linear regression analysis*. John Wiley & Sons.
- Seger, C. (2018). An investigation of categorical variable encoding techniques in machine learning: Binary versus one-hot and feature hashing (Degree project, First cycle, 15 credits). Stockholm, Sweden.
- Sevinç, A., & Özyurt, F. (2022). Classification of recyclable waste using deep learning architectures. *Firat University Journal of Experimental and Computational Engineering*, 1(3), 122-128.
- Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding machine learning: From theory to algorithms*. Cambridge university press.
- Sharif, M. I., Li, J. P., Khan, M. A., & Saleem, M. A. (2020). Active deep neural network features selection for segmentation and recognition of brain tumors using MRI images. *Pattern Recognition Letters*, 129, 181-189.
- Sharma, A. K., Nandal, A., Dhaka, A., Zhou, L., Alhudhaif, A., Alenezi, F., & Polat, K. (2023). Brain tumor classification using the modified ResNet50 model based on transfer learning. *Biomedical Signal Processing and Control*, 86, 105299.
- Shin, S., Shin, D., & Kang, N. (2023). Topology optimization via machine learning and deep learning: A review. *Journal of Computational Design and Engineering*, 10(4), 1736-1766.
- Shinde, P. P., & Shah, S. (2018). A review of machine learning and deep learning applications. In 2018 Fourth international conference on computing communication control and automation (ICCUBEA) (pp. 1-6). IEEE.

- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48.
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14, 199-222.
- Sujatha, K., & Rao, B. S. (2023, February). Densenet201: a customized DNN model for multi-class classification and detection of tumors based on brain MRI Images. In 2023 Fifth International conference on electrical, computer and communication technologies (ICECCT) (pp. 1-7). IEEE.
- Sultan, H.H.; Salem, N.M.; Al-Atabany, W. Multi-Classification of Brain Tumor Images Using Deep Neural Network. *IEEE Access* 2019, 7, 69215–69225.
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction* (Second edi). A Bradford Book.
- Süslü, A. (2019). Doğa ve insan bilimlerinde yapay zekâ uygulamaları. *Akademia Doğa ve İnsan Bilimleri Dergisi*, 5(1), 1-10.
- Şener, A., & Ergen, B. (2023). Enhancing Brain Tumor Detection on MRI Images Using an Innovative VGG-19 Model-Based Approach. *Sakarya University Journal of Science*, 27(5), 1128-1140.
- Torralba, A., & Efros, A. A. (2011, June). Unbiased look at dataset bias. In *CVPR 2011* (pp. 1521-1528). IEEE.
- Turner, R. (2016). Uses, misuses, new uses and fundamental limitations of magnetic resonance imaging in cognitive science. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 371(1705), 20150349.
- Upadhyay, D., Manwal, M., Kukreja, V., & Sharma, R. (2024, May). Deep Learning-based VGGNet, GoogleNet, and DenseNet121 Models for Cervical Cancer Prediction. In 2024 5th International Conference for Emerging Technology (INCET) (pp. 1-6). IEEE.
- Uwimana, A., Gnecco, G., & Riccaboni, M. (2025). Artificial intelligence for breast cancer detection and its health technology assessment: A scoping review. *Computers in biology and medicine*, 184, 109391.
- Üngüren, E. (2016). Beynin Nöroanatomik ve Nörokimsayal Yapısının Kişilik ve Davranış Üzerindeki Etkisi. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 7(1).
- van Dijken, B. R., van Laar, P. J., Smits, M., Dankbaar, J. W., Enting, R. H., & van der Hoorn, A. (2019). Perfusion MRI in treatment evaluation of glioblastomas: Clinical relevance of current and future techniques. *Journal of Magnetic Resonance Imaging*, 49(1), 11-22.
- Wang, S. H., & Zhang, Y. D. (2020). DenseNet-201-based deep neural network with composite learning factor and precomputation for multiple sclerosis classification. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 16(2s), 1-19.

- Wang, X., Wang, S., Liang, X., Zhao, D., Huang, J., Xu, X., ... & Miao, Q. (2022). Deep reinforcement learning: A survey. *IEEE Transactions on Neural Networks and Learning Systems*, 35(4), 5064-5078.
- Weller, M., Wick, W., Aldape, K., Brada, M., Berger, M., Pfister, S. M., ... & Stupp, R. (2015). Glioma. *Nature Reviews Disease Primers*, 1(1), 15017.
- Whang, S. E., Roh, Y., Song, H., & Lee, J. G. (2023). Data collection and quality challenges in deep learning: A data-centric ai perspective. *The VLDB Journal*, 32(4), 791-813.
- Wiemels, J., Wrensch, M., & Claus, E. B. (2010). Epidemiology and etiology of meningioma. *Journal of neuro-oncology*, 99, 307-314.
- Williams, B. A., McClung, A., Blakemore, L. C., Shah, S. A., Pawelek, J. B., Sponseller, P. D., ... & Pediatric Spine Study Group. (2020). MRI utilization and rates of abnormal pretreatment MRI findings in early-onset scoliosis: review of a global cohort. *Spine deformity*, 8, 1099-1107.
- Xiao, Y. D., Paudel, R., Liu, J., Ma, C., Zhang, Z. S., & Zhou, S. K. (2016). MRI contrast agents: Classification and application. *International journal of molecular medicine*, 38(5), 1319-1326.
- Yenikaya, M. A. (2024). Resnet101 And Googlenet Deep Learning Models: Comparing Success Levels In The Health Sector. *Kafkas Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 15(29), 390-409.
- Younis, A., Qiang, L., Nyatega, C. O., Adamu, M. J., & Kawuwa, H. B. (2022). Brain tumor analysis using deep learning and VGG-16 ensembling learning approaches. *Applied Sciences*, 12(14), 7282.
- Yousaf, T., Dervenoulas, G., & Politis, M. (2018). Advances in MRI methodology. *International review of neurobiology*, 141, 31-76.
- Yüksel, Z. (2019). Manyetik rezonans görüntüleme fizik temelleri ve sistem bileşenleri. *Black Sea Journal of Engineering and Science*, 2(2), 57-65.
- Zeineldin, R. A., Karar, M. E., Burgert, O., & Mathis-Ullrich, F. (2022, September). Multimodal CNN networks for brain tumor segmentation in MRI: a BraTS 2022 challenge solution. In *International MICCAI Brainlesion Workshop* (pp. 127-137). Cham: Springer Nature Switzerland.
- Zha, D., Bhat, Z. P., Lai, K. H., Yang, F., & Hu, X. (2023). Data-centric ai: Perspectives and challenges. In *Proceedings of the 2023 SIAM International Conference on Data Mining (SDM)* (pp. 945-948). Society for Industrial and Applied Mathematics.
- Zhang, J., Qin, Z., Yin, H., Ou, L., & Zhang, K. (2019). A feature-hybrid malware variants detection using CNN based opcode embedding and BPNN based API embedding. *Computers & Security*, 84, 376-392.
- Zhang, Z. (2016). Introduction to machine learning: k-nearest neighbors. *Annals of translational medicine*, 4(11).

- Zhou, S. K., Le, H. N., Luu, K., Nguyen, H. V., & Ayache, N. (2021). Deep reinforcement learning in medical imaging: A literature review. *Medical image analysis*, 73, 102193.
- Zhou, Z. H. (2021). *Machine learning*. Springer nature.
- Zhuang, D., Zhang, H., Hu, G., & Guo, B. (2022). Recent development of contrast agents for magnetic resonance and multimodal imaging of glioblastoma. *Journal of Nanobiotechnology*, 20(1), 284.
- Zong, H., Verhaak, R. G., & Canoll, P. (2012). The cellular origin for malignant glioma and prospects for clinical advancements. *Expert Review of Molecular Diagnostics*, 12(4), 383-394



ÖZGEÇMİŞ

Seda ARIKAN

ÖĞRENİM BİLGİLERİ

Yüksek Lisans 2023-2025	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı, Antalya
Lisans 2014-2018	Gümüşhane Üniversitesi Mühendislik Fakültesi Genetik ve Biyomühendislik Bölümü

MESLEKİ VE İDARİ GÖREVLER

Fresenius Medical Care GBMH 21.06.2023-17.12.2024	Bitmiş Ürün Teknolojik Kalite Kontrol Analisti
Labgen Laboratuvar Sistemleri San. Tic. A.Ş. 05.2019-01.06.2022	Aplikasyon Uzmanı

PROJE GÖREVLERİ

Araştırmacı; “Resveratrol ile Muamele Edilen Glioblastoma Hücrelerinde Darbeli Elektromanyetik Alan Maruziyetinin Proapoptotik veP13K/AKT/mTOR Sinyal Yolaklarında Olası Moleküler Etkileri”, TÜBİTAK 1002, Proje No: 123R068, Yürütücü: Doç. Dr. Çiğdem Saraç.

ESERLER

Uluslararası yayınevleri tarafından yayımlanmış kitaplarda bölüm yazarlığı

ARIKAN, S., ÜNCÜ, Y. A., & SARAÇ, Ç., (2024). A Deep Learning-based Reinforcement Algorithm for the Diagnosis of Glioma. Springer Series. (Basım aşamasında).

Uluslararası bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler

ARIKAN, S., ÜNCÜ, Y. A., & SARAÇ, Ç., (2024). A Deep Learning-based Reinforcement Algorithm for the Diagnosis of Glioma . 6th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2024), Poland

