

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**BEYİN TÜMÖRLERİNİN MR GÖRÜNTÜLERİ ÜZERİNDEN DERİN
ÖĞRENME YÖNTEMİYLE TESPİTİ VE SINIFLANDIRMASI**

Merve KÖRDEMİR

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

TEMMUZ 2021

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**BEYİN TÜMÖRLERİNİN MR GÖRÜNTÜLERİ ÜZERİNDEN DERİN
ÖĞRENME YÖNTEMİYLE TESPİTİ VE SINIFLANDIRMASI**

Merve KÖRDEMİR

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

TEMMUZ 2021

ANTALYA

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

**BEYİN TÜMÖRLERİNİN MR GÖRÜNTÜLERİ ÜZERİNDEN DERİN
ÖĞRENME YÖNTEMİYLE TESPİTİ VE SINIFLANDIRMASI**

**Merve KÖRDEMİR
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS**

**Akdeniz Üniversitesi Bilimsel Araştırma Projeleri tarafından FYL-2020-5310
nolu proje ile desteklenmiştir.**

TEMMUZ 2021

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BEYİN TÜMÖRLERİNİN MR GÖRÜNTÜLERİ ÜZERİNDEN DERİN
ÖĞRENME YÖNTEMİYLE TESPİTİ VE SINIFLANDIRMASI**

Merve KÖRDEMİR
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS

Bu tez 05/07/2021 tarihinde jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.

Prof. Dr. Ahmet BOZKURT (Danışman)
Doç. Dr. Kerim Kürşat ÇEVİK
Doç. Dr. Mehmet Erkan YÜKSEL
Doç. Dr. Emre DANDIL
Dr. Öğr. Üyesi Pelin AKŞİT ÇİRİŞ

ÖZET

BEYİN TÜMÖRLERİNİN MR GÖRÜNTÜLERİ ÜZERİNDEN DERİN ÖĞRENME YÖNTEMİYLE TESPİTİ VE SINIFLANDIRMASI

Merve KÖRDEMİR

Yüksek Lisans, Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ahmet BOZKURT

İkinci Danışman: Doç. Dr. Kerim Kürşat ÇEVİK

Temmuz 2021; 80 sayfa

Biyomedikal görüntüler üzerinden beyin tümörlerinin hızlı ve doğru tespit edilebilmesi, hastalara erken ve etkili tedavi olanağının yanı sıra iyi bir yaşam kalitesi sağlar. Son yıllarda bilgisayar donanımlarının gelişmesi ve çok sayıda ilgili veriye kolaylıkla ulaşılabilmesi yapay zekâ yöntemlerinin birçok alana uygulanmasına imkân sağlamıştır. Buna paralel olarak yapay zekânın uygulamaları olan makine öğrenmesi ve derin öğrenme teknolojileri de gelişim göstererek yaygınlaşmıştır. Derin öğrenme teknikleri günümüzde uzman doktorların biyomedikal görüntülerdeki anomalileri tespitine yardımcı olmakta ve böylece hastalıkların veya vücut içi anomalilerin daha erken, hızlı ve yüksek doğrulukla teşhisini mümkün kılmaktadır. Bu tez çalışmasında, üç tip beyin tümörünün (meninjiyom, gliom veya hipofiz) hacimlerini komşu doku ve yapılardan doğru bir şekilde bölütlemek ve bu tümörlerin doğru sınıflandırılmasını sağlamak için transfer öğrenme modelleriyle birlikte Faster R-CNN mimarisine maske (bölütleme) dalının eklenmesiyle oluşturulmuş Mask R-CNN (Maskeli B-ESA) tekniği uygulanmıştır. Mask R-CNN ile tespit, bölütleme ve sınıflandırma işlemleri tek bir çatı altında ve ilgili veri seti üzerinde görüntü işleme tekniklerine gerek duyulmadan gerçekleştirilmiştir. Çalışmamızda Mask R-CNN mimarisinin temel ağı için daha önce hem COCO hem de ImageNet veri setleri ile eğitilmiş ResNet-50 ve ResNet-101 mimarileri kullanılmıştır. Önerilen model eğitimleri COCO veya Imagenet başlangıç ağırlıkları ile başlatılmıştır. Test süreci sonunda COCO görüntüleri üzerinde önceden eğitilmiş ResNet-101 omurgasının sınıflandırma başarısının (%75) aynı veri setiyle eğitilmiş ResNet-50 omurgasının sınıflandırma başarısından (%55) daha yüksek olduğu gözlemlenmiştir. ResNet-50 omurgası ile ise ImageNet veri seti üzerindeki sınıflandırma doğruluğu (%87) aynı veri setiyle eğitilmiş ResNet-101 omurgasının sınıflandırma doğruluğuna (%37) kıyasla daha yüksek elde edilmiştir. Modellerin tümör türlerindeki bölütleme başarısını gösteren kesişim (IoU) ortalamaları meninjiyom tümörü için %83, gliom tümörü için %58, hipofiz tümörü için %75 olarak bulunmuştur. Mask R-CNN mimarisinin sağlık sektöründeki sistemlere aktarılabilir olması uzmanların beyin tümörlerini erken teşhisine yardımcı olacaktır.

ANAHTAR KELİMELER: Beyin tümör tespiti, Derin öğrenme, Maskeli B-ESA, MR görüntüsü sınıflandırma, Transfer öğrenme

JÜRİ:

Prof. Dr. Ahmet BOZKURT

Doç. Dr. Kerim Kürşat ÇEVİK

Doç. Dr. Mehmet Erkan YÜKSEL

Doç. Dr. Üyesi Emre DANDIL

Dr. Öğr. Üyesi Pelin ÇİRİŞ



ABSTRACT

DETERMINATION AND CLASSIFICATION OF BRAIN TUMORS ON MR IMAGES BY DEEP LEARNING METHOD

Merve KÖRDEMİR

MSc Thesis in Biomedical Engineering

Supervisor: Prof. Dr. Ahmet BOZKURT

Co-advisor: Assoc. Prof. Dr. Kerim Kürşat ÇEVİK

July 2021; 80 pages

Rapid and accurate detection of brain tumors through biomedical images provides early and effective treatment for patients, as well as a good quality of life. In recent years, development of computer hardware and easy access to a large number of relevant data have enabled application of artificial intelligence methods to many areas. In parallel with this, machine learning and deep learning technologies, which are applications of artificial intelligence, have also developed and become widespread. Today, deep learning techniques help specialist doctors to detect anomalies in biomedical images, thus enabling earlier, faster and more accurate diagnosis of diseases or intra-body anomalies. In this thesis, the Mask R-CNN technique, which was created by adding a mask (segmentation) branch to Faster R-CNN architecture with transfer learning models, was applied to accurately segment volumes of three types of brain tumors (meningioma, glioma or pituitary) from neighboring tissues and structures as well as to ensure correct classification of these tumors. Detection, segmentation and classification procedures were carried out with Mask R-CNN under a single roof and without the need for applying image processing techniques on the related data set. In our study, ResNet-50 and ResNet-101 architectures, which were trained with both COCO and ImageNet datasets, were used for the basic network of the Mask R-CNN architecture. The proposed model trainings were started with COCO or Imagenet initial weights. At the end of the test process, it was observed that the classification success (75%) of the ResNet-101 backbone pre-trained on COCO images was higher than the classification success (55%) of the ResNet-50 backbone trained with the same data set. With the ResNet-50 backbone, the classification accuracy on the ImageNet dataset (87%) was higher than the classification accuracy (37%) of the ResNet-101 backbone trained on the same dataset. The IoU averages showing the segmentation success of the models in tumor types were found to be 83% for meningioma tumors, 58% for glioma tumors, and 75% for pituitary tumors. The portability of the Mask R-CNN architecture to systems in the healthcare industry will help specialists to detect brain tumors early.

KEYWORDS: Brain tumor detection, Deep learning, Mask R-CNN, MR image classification, Transfer learning

COMMITTEE: Prof. Dr. Ahmet BOZKURT
Assoc. Prof. Dr. Kerim Kürşat ÇEVİK
Assoc. Prof. Dr. Mehmet Erkan YÜKSEL
Assoc. Prof. Dr. Emre DANDIL
Assist. Prof. Dr. Pelin ÇİRİŞ



ÖNSÖZ

İlk olarak tez çalışmamın her aşamasında yapıcı önerilerini, bilgi ve tecrübelerini benden esirgemeyen çok değerli tez danışman hocam Prof. Dr. Ahmet BOZKURT'a çok teşekkür ederim. Ardından tez çalışmamın başlangıcından sonuna kadar akademik tecrübelerini, bilgisini, zamanını benimle paylaşan çok kıymetli hocam Doç. Dr. Kerim Kürşat ÇEVİK'e teşekkürlerimi sunarım.

Bu çalışmanın veri setini oluştururken benden yardımlarını esirgemeyen Akdeniz Üniversitesi Biyomedikal Mühendisliği Ana Bilim Dalı'nda yüksek lisanslarına devam eden değerli arkadaşlarım Soner ÇİVİLİBAL, Esra SİVRİKAYA ve Bedia ŞAYIK'a teşekkür ederim. Ayrıca teknik bilgisiyle bana destek olan Salih Mervan TAŞ'a teşekkür ederim.

Ardından Akdeniz Üniversitesi Biyomedikal Mühendisliği Anabilim Dalı'ndaki tüm öğretim üyelerine ve Arş. Gör. Hacer KUDUZ'a akademik desteklerinden dolayı teşekkür ederim.

Tez dönemi sürecimde bana motivasyon sağlayan ve manevi desteklerini hep hissettiğim Medine AÇAR, Hatice ASRİ, Eda ULUSOY, Yasemin KARAHAN, Zeynep ÇOBAN, Merve ÖZDAŞ, Betül MAYLI, Nur AKDEDE, Fatma ONAT, Nilgün ÖZKURT ve diğer tüm arkadaşlarıma teşekkür ederim.

Son olarak hayatımın her anında manevi desteklerini ve sevgilerini hep hissettiğim canım aileme çok teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	iii
ÖNSÖZ	v
AKADEMİK BEYAN	ix
SİMGELER VE KISALTMALAR.....	x
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ	xvii
1. GİRİŞ	1
2. KAYNAK TARAMASI	4
3. MATERYAL VE METOT	15
3.1. Beyin ve Beyin Tümörleri.....	15
3.1.1. Genel bilgi	15
3.1.2. Prevelans (Yaygınlık).....	16
3.1.3. Semptomlar ve bulgular.....	17
3.1.4. Beyin tümör çeşitleri ve evreleri.....	17
3.2. Beyin Tümörlerinin Tanısında Kullanılan Görüntüleme Teknikleri.....	18
3.2.1. Giriş/Genel teknikler.....	18
3.2.2. MR görüntülemenin ilkeleri.....	20
3.3. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme	24
3.3.1. Makine öğrenmesi	25
3.3.2. Derin öğrenme	29
3.4. Evrişimli Sinir Ağları ve Katmanları	30
3.4.2. Evrişim (Konvolüsyon) katmanı.....	30
3.4.3. Aktivasyon fonksiyonları.....	32
3.4.4. Havuzlama katmanı	33
3.4.5. Tam bağlı katman (Fully connected layer-Dense).....	34
3.4.6. Seyreletme katmanı (Dropout)	34
3.5. Transfer Öğrenme.....	35
3.6. Derin Öğrenme Modellerinin Eğitiminde Kullanılan Büyük Veri setleri.....	36
3.6.1. ImageNet.....	36
3.6.2. COCO (The Common Objects in Context)	36

3.7. ESA Mimarileri	36
3.7.1. LeNet	36
3.7.2. AlexNet.....	37
3.7.3. VGGNet.....	37
3.7.4. GoogLeNet	38
3.7.5. ResNet.....	39
3.8. Bölge Tabanlı Nesne Tanıma ESA Mimarileri	39
3.8.1. B-ESA.....	40
3.8.2. H B-ESA.....	40
3.8.3. DH B-ESA.....	41
3.8.4. Maskeli B-ESA.....	42
3.9. Derin Öğrenme Modellerinde Kullanılan Hiperparametreler ve Optimizasyon Yöntemleri.....	43
3.9.1. Aktivasyon fonsiyonları.....	43
3.9.2. Eğitim devir sayısı (Epoch)	43
3.9.3. Öğrenme hızı (Learning Rate)	44
3.9.4. Optimizasyon algoritmaları	45
3.10. Model Performansını Değerlendirme Metrikleri.....	45
3.10.1. Sınıflandırma problemlerinde kullanılan değerlendirme metrikleri	45
3.10.2. Bölütleme problemlerinde kullanılan değerlendirme metrikleri	47
3.11. Çalışmada Kullanılan Yazılımlar ve Python Kütüphaneleri	48
3.11.1. VIA	48
3.11.2. Python	49
3.11.3. Numpy	49
3.11.4. Scikit-plot	49
3.11.5. Tensorflow	49
3.11.6. Keras	49
4. BULGULAR.....	50
4.1. Veri Seti Oluşturma.....	50
4.2. Veri Setindeki Görüntülerin VIA ile Etiketlenmesi	54
4.3. Önerilen Maskeli B-ESA Modelleri.....	55
4.4. Modelin Eğitiminde Kullanılan Hiperparametreler	56

4.5. Model Eğitim ve Test Sonuçları.....	57
5. TARTIŞMA	64
6. SONUÇLAR	69
7. KAYNAKLAR	71
ÖZGEÇMİŞ	



AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Beyin Tümörlerinin MR Görüntüleri Üzerinden Derin Öğrenme Yöntemiyle Tespiti ve Sınıflandırması” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

05/07/2021

Merve KÖRDEMİR



SİMGELER VE KISALTMALAR

Simgeler

.	: Ondalık ayırıcı
,	: Binlik ayırıcı
b	: Bias
$y(k)$	: Bir nöronun k anındaki matematiksel fonksiyon değeri
$\sigma(x)$	: Sigmoid aktivasyon fonksiyonu, $x \rightarrow \pm \infty$
$f(x)$	: ReLu aktivasyon fonksiyonu, $x \rightarrow \pm \infty$
$x_i(k)$	: Bir nöronun i 'nci pozisyonu k zamanındaki değer fonksiyonu
Σ	: Toplam sembolü
F	: Transfer fonksiyonu
*	: Evrişim işlemi

Kısaltmalar

AdaGrad	: Adaptive Gradient Algorithm
Adam	: Adaptive Moment Estimation
ANN	: Artificial Neural Network
BGD	: Batch Gradient Descent
BTF	: Brain Tumor Figshare
BTK	: Brain Tumor Kaggle
BBR	: Bounding Box Regressor
CT	: Computed Tomography
CLAHE	: Contrast Limited Adaptive Histogram Equalization
CNN	: Convolutional Neural Network
DSC	: Dice Score
DTs	: Decision Trees

ESA	: Evriřimli Sinir Ađı
Fast R-CNN	: Fast Region Based Convolutional Neural Network
H B-ESA	: Hızlı Bölge Tabanlı Evriřimli Sinir Ađı
Faster R-CNN	: Faster Region Based Convolutional Neural Network
DH B-ESA	: Daha Hızlı Bölge Tabanlı Evriřimli Sinir Ađı
FLAIR	: Fluid Attenuated Inversion Recovery
FN	: False Negative
FP	: False Positive
FPN	: Feature Pyramid Network
GAN	: Generative Adversarial Networks
GD	: Gradient Descent
GPU	: Graphics Processing Unit
ILSVRC	: ImageNet Large Scale Visual Recognition Challenge
IoU	: Intersection over Union
KNN	: k-Nearest Neighbors
mAP	: Mean Average Precision
Maskeli B-ESA	: Maskeli Bölge Tabanlı Evriřimli Sinir Ađı
Mask R-CNN	: Mask Region Based Convolutional Neural Network
MBGD	: Mini Batch Gradient Descent
MCC	: Matthews Correlation Coefficient
MR	: Manyetik Rezonans
MRG	: Manyetik Rezonans Görüntüleme
MRS	: Magnetic Resonance Spectroscopy
NCIS	: National Cancer Institute Statistics
PCA	: Principal Component Analysis
PET	: Positron Emission Tomography

R-CNN	: Region Based Convolutional Neural Networks
B-ESA	: Bölge Tabanlı Evrişimli Sinir Ağı
ReLU	: Rectified Linear Unit
RF	: Radyo Frekans
RGB	: Red, Green, Blue
RMSprop	: Root Mean Squared Prop
RNN	: Recurrent Nerual Network
ROI	: Regions of Interest
RoIAlign	: RoI Align
RPN	: Region Proposal Network
SGD	: Stochastic Gradient Descent
SGDM	: Stochastic Gradient Descent with Momentum
SGDR	: Stochastic Gradient Descent with Restarts
SPECT	: Single-Photon-Emission Computed Tomography
SVM	: Support Vector Machine
Tanh	: Hiperbolik Tanjant
TCIA	: The Cancer Imaging Archive
TE	: Time to Echo
TN	: True Negative
TP	: True Positive
TR	: Repetition Time
VIA	: VGG (Visual Geometry Group) Image Annotator
YZ	: Yapay Zekâ

ŞEKİLLER DİZİNİ

Şekil 1.1. Figshare beyin tümör görüntü veri setinde bulunan MR görüntülerinden alınmış örnek tümör çeşitleri: a) meninjiyom; b) gliom; c) hipofiz tümörü.....	1
Şekil 3.1. Beyin ve yakınındaki anatomik yapılar	15
Şekil 3.2. Beynin ana bölümleri.....	15
Şekil 3.3. MR görüntülerinde beyin tümörlerinin sınıf temsili: a) iyi huylu tümör; b) kötü huylu tümör	16
Şekil 3.4. Birincil beyin tümörlerinin dağılımı (sol) ile gliomların alt tiplerinin (sağ) dağılımlarının gösterimi	17
Şekil 3.5. Birincil beyin tümörlerinin (gliom, meninjiyom, hipofiz) sırasıyla aksiyel (sol), koronal (orta) ve sağıtal (sağ) düzlemlerdeki MR görüntüleri	18
Şekil 3.6. Kontrast-artırılmış MRG (üst sıra) ve çoklu PET izleyicilerin kullanımıyla glioblastoma beyin tümörünün konumunun görüntülenmesi: (a) [18F]-2-fluoro-2-deoxy-D-glucose ([18F]FDG); (b) O-(2-[18F]-fluoroethyl)-L-tyrosine ([18F]FET), (c) [18F] Fluorocholine; (d) 1-(2-Nitro-imidazolyl)-3-[18F]fluoro-2-propanol ([18F]FMISO); (e) 3'-deoxy-3'-[18F]fluorothymidine ([18F]FLT)	19
Şekil 3.7. Hidrojen çekirdeğinin manyetik momenti	20
Şekil 3.8. MRG sisteminin temel parçaları	21
Şekil 3.9. Farklı MR sekanslarındaki beyin kesit görüntüleri: a) T1 ağırlıklı; b) T2 ağırlıklı; c) PD ağırlıklı	23
Şekil 3.10. MR görüntü sekansları kullanımı ile gliom (glioblastoma) tümörünün görünümü: a) Kontrast madde sonrası (gadolinyum ile geliştirilmiş) T1 ağırlıklı görüntü; b) T2 ağırlıklı görüntü; c) FLAIR görüntü.....	23
Şekil 3.11. Beyin MR görüntülerinin farklı düzlemdeki kesitleri; a) aksiyel düzlemdeki beyin görüntüsü; b) sağıtal düzlemdeki beyin MR görüntüsü; c) koronal düzlemdeki beyin MR görüntüsü.....	24
Şekil 3.12. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki.....	25
Şekil 3.13. Makine öğrenmesi algoritmaları: A) Gözetimli öğrenme algoritması; B) Gözetimsiz öğrenme algoritması; C) Takviyeli öğrenme algoritması	26
Şekil 3.14. Biyolojik nöronlar ve yapay nöronlar arasındaki benzerlik: a) biyolojik sinir hücre yapısı ve sinir hücrelerinin sinaptik bağlantısı; b) yapay nöronun yapısı.....	27

Şekil 3.15. Biyolojik ve yapay nöronun tasarımı: a) Biyolojik nöronun bölümlerinin (soma, dendrit ve akson) temsili gösterilmiştir; b) Yapay nöronun girişleri, ağırlıkları, toplama fonksiyonu, transfer fonksiyonu, bias değeri ve çıkış temsili gösterimi.....	28
Şekil 3.16. Çok katmanlı perseptronun örüntü tanıma kabiliyeti üzerindeki katman sayısının etkisi.....	29
Şekil 3.17. YSA mimari yapıları, a) Giriş ve çıkış katmanları arasında 3 gizli katman bulunan derin öğrenme sinir ağı; b) Giriş ve çıkış katmanları arasında 1 gizli katman bulunan temel yapay sinir ağı.....	29
Şekil 3.18. ESA temel yapısı	30
Şekil 3.19. Evrişim katmanında yapılan işlemler. (Kare gri tonlamalı 5*5 boyutunda evrişim filtreleri, daire içine alınmış * işareti evrişim işlemini ve ϕ işareti aktivasyon fonksiyonunu gösterir.).....	31
Şekil 3.20. Evrişim işlemi.....	31
Şekil 3.21. ESA'nda yaygın kullanılan aktivasyon fonksiyonları: a) sigmoid; b) hiperbolik tanjant (tanh); c) düzeltilmiş doğrusal birim (rectified linear unit (ReLU)).....	32
Şekil 3.22. Maksimum havuzlama ve ortalama havuzlama işlem örnekleri.....	34
Şekil 3.23. Derin sinir ağı, a) tamamen bağlantılı sinir ağı; b) bırakma sonrası tamamen bağlı sinir ağı	35
Şekil 3.24. LeNet mimari yapısı	37
Şekil 3.25. AlexNet mimari yapısı (paralel iki GPU bölümlere ile).....	37
Şekil 3.26. VGGNet mimari yapısı.....	38
Şekil 3.27. GoogLeNet mimari yapısı	38
Şekil 3.28. 34 katmana sahip klasik derin sinir ağı ve ResNet model yapıları.....	39
Şekil 3.29. ResNet artık (residual) öğrenmenin yapı taşı	39
Şekil 3.30. B-ESA mimarisi	40
Şekil 3.31. H B-ESA mimarisi.....	41
Şekil 3.32. DH B-ESA mimarisi.....	42
Şekil 3.33. Maskeli B-ESA mimarisi (özellik çıkarımı için özellik piramit ağı (Feature Pyramid Network; FPN) omurgasına sahip ResNet-101 mimarisi kullanılmıştır).....	42

Şekil 3.34. Sinir ağlarında sıklıkla kullanılan aktivasyon fonksiyonları	43
Şekil 3.35. Öğrenme hızının artan eğitim turuna bağlı olarak hata değerine etkisi	44
Şekil 3.36. Karmaşıklık matrisi	46
Şekil 3.37. IoU'nun resim ile gösterimi	47
Şekil 3.38. VIA görüntü açıklayıcı yazılımı ile bir görüntü için gerçek referans maskesi oluşturma	48
Şekil 3.39. VIA aracı ile gerçek referans maskesi oluşturulmuş MR görüntüleri: a) meninjiyom; b) gliom; ve c) hipofiz tümörü	49
Şekil 4.1. FBT veri setinin kesitsel düzlemlerdeki dağılımını gösteren pasta grafiği	51
Şekil 4.2. Veri setindeki 13. ".mat" dosyasının aksiyel düzlemde meninjiyom tümör örneği: a) MR görüntüsü; b) ikili tümör bölge görüntüsü; c) tümör bölgesinin resim üzerinde renklendirilen görüntüsü	51
Şekil 4.3. Veri setindeki 719. ".mat" dosyasının aksiyel düzlemde gliom tümör örneği: a) MR görüntüsü; b) ikili tümör bölge görüntüsü; c) tümör bölgesinin resim üzerinde renklendirilen görüntüsü	52
Şekil 4.4. Veri setindeki 1336. ".mat" dosyasının aksiyel düzlemde hipofiz tümörü örneği: a) MR görüntü; b) ikili tümör bölge görüntüsü; c) tümör bölgesinin resim üzerinde renklendirilen görüntüsü	52
Şekil 4.5. FBT veri setinin tümör sınıflarındaki dağılımını gösteren pasta grafikleri: a) eğitim veri seti dağılımı; b) test veri seti dağılımı	53
Şekil 4.6. Veri setindeki 13. ".mat" dosyasının aksiyel düzlemde meninjiyom tümör örneği: a) VIA aracı ile tümör sınırlarının gösterimi; b) .json format ile gösterimi	54
Şekil 4.7. Eğitim veri setindeki 719. ".mat" dosyasının aksiyel düzlemde gliom tümör örneği: a) VIA aracı ile tümör sınırlarının gösterimi; b) .json format ile gösterimi	54
Şekil 4.8. Veri setindeki 1336. ".mat" dosyasının aksiyel düzlemde hipofiz tümör örneği: a) VIA aracı ile tümör sınırlarının gösterimi; b) .json format ile gösterimi	55
Şekil 4.9. Çalışmada kullanılan Maskeli B-ESA mimarisi	56
Şekil 4.10. a) Karmaşıklık matrisi; b) çalışmada kullanılan değerlendirme metriklerinin dört sınıf için hesaplamaları	58
Şekil 4.11. ResNet-50 omurgası ve COCO başlangıç ağırlığı kullanılan modelin 1000 eğitim turunda elde edilen karmaşıklık matris maksimum skor için sonuçları: a) eğitim veri seti (2298 görüntü) sonuçları; b) test veri seti (766 görüntü) sonuçları ...	58

Şekil 4.12. ResNet-101 omurgası ve COCO başlangıç ağırlığı kullanılan modelin 1000 eğitim turunda elde edilen karmaşıklık matris maksimum skor için sonuçları: a) eğitim veri seti (2298 görüntü) sonuçları; b) test veri seti (766 görüntü) sonuçları...	59
Şekil 4.13. ResNet-50 omurgası ve ImageNet başlangıç ağırlığı kullanılan modelin 1000 eğitim turunda elde edilen karmaşıklık matris maksimum skor için sonuçları: a) eğitim veri seti (2298 görüntü) sonuçları; b) test veri seti (766 görüntü) sonuçları...	59
Şekil 4.14. ResNet-101 omurgası ve ImageNet başlangıç ağırlığı kullanılan modelin 1000 eğitim turunda elde edilen karmaşıklık matris maksimum skor için sonuçları: a) eğitim veri seti (2298 görüntü) sonuçları; b) test veri seti (766 görüntü) sonuçları...	59
Şekil 4.15. Örnek bir görüntü üzerinde tek bir aday bölge için sınıflandırma aşamaları: a) etiketli görüntü; b) önerilen sınırlayıcı kutu; c) seçilen bölge	61
Şekil 4.16. Örnek bir görüntü üzerinde birden fazla aday bölge için segmentasyon aşamaları: a) etiketli görüntü; b) önerilen sınırlayıcı kutular; c) seçilen bölge (maksimum skor ve maksimum kesişim).....	62
Şekil 4.17. Örnek bir görüntü üzerinde birden fazla aday bölge için segmentasyon aşamaları: a) etiketli görüntü; b) önerilen sınırlayıcı kutular; c) seçilen bölge (maksimum skor); d) maksimum kesişim (IoU).....	62
Şekil 4.18. Örnek bir görüntü üzerinde birden fazla aday bölge için segmentasyon aşamaları: a) etiketli görüntü; b) önerilen sınırlayıcı kutular c) seçilen bölge (hem maksimum skor hem de maksimum IoU için aynı)	63
Şekil 5.1. Kaldera vd. (2019) tarafından yapılan beyin tümör sınıflandırması ve segmentasyonu çalışması için önerilen model	64
Şekil 5.2. Avşar and Salçin (2019) tarafından önerilen modelin beyin tümörlerinin tespiti ve sınıflandırması: a) meninjiyom; b) gliom; c) hipofiz tümörü	66
Şekil 5.3. Bu tez çalışmasında önerilen modelin (ResNet-50+Imagenet model başlangıç ağırlığı ile (maksimum skor kabulünde) beyin tümörlerinin tespiti, sınıflandırması ve bölütlenmesi, a) meninjiyom; b) gliom; c) hipofiz tümörü	66
Şekil 5.4. Masood vd. (2021) tarafından önerilen yöntemin blok diyagramı	67
Şekil 5.5. Masood vd. (2021) tarafından önerilen yöntemin yapısı.....	67
Şekil 5.6. Bu tez çalışması için önerilen modelin blok diyagramı.....	68

ÇİZELGELER DİZİNİ


Çizelge 4.1. Figshare Beyin Tümörü (FBT) veri seti kesitsel düzlemlerdeki dağılımı	50
Çizelge 4.2. FBT veri seti üzerinden 4 kat çapraz doğrulama sonuçları	53
Çizelge 4.3. Deneysel çalışmada kullanılan FBT veri setinin tümör türlerindeki dağılımı	53
Çizelge 4.4. Önerilen modellerin eğitiminde kullanılan optimize edilmiş parametreler.....	56
Çizelge 4.5. Maskeli B-ESA mimarileri için sınıflandırma sonuçları (M: Meninjiyom, G: Gliom, H: Hipofiz, Ort.:Ortalama).....	60
Çizelge 4.6. Maskeli B-ESA modellerinin bölütleme sonuçları (M: Meninjiyom, G: Gliom, P: Hipofiz).....	61

1. GİRİŞ

Hücrelerin kontrolsüz çoğalması nedeniyle dokuların anormal şekilde büyümesi sonucu insan vücudunda fizyolojik işleve sahip olmayan tümörlü dokular oluşabilir (Abd-Ellah vd. 2019). Amerikan Ulusal Kanser Enstitüsü (National Cancer Institute Statistics; NCIS) istatistiklerine göre tüm kanser vakalarının %1.3'ünü beyinde ortaya çıkan tümörlerin oluşturduğu düşünülmektedir (Anonymous 1). Beynin boyutunu ve basıncını artırarak işlevselliğini bozabilen bu tip tümörlerin beyinde bulunduğu yere göre hastada dikkat ve konsantrasyon eksikliği, koordinasyon bozukluğu, konuşmada değişiklikler, baş ağrıları, halüsinasyonlar, anksiyete, nöbetler, hafıza kaybı gibi farklı nörolojik semptomlara yol açtığı bilinmektedir (Abd-Ellah vd. 2019; Amin vd. 2020; Comelli vd. 2017). Bu yönleriyle hastanın yaşam kalitesini önemli ölçüde etkileyebilen beyin tümörlerinin ölümcül potansiyeli de vardır. NCIS verileri, beyin ve diğer sinir sistemi kanserleri nedeniyle ABD'de ölen kişi sayısının 2020 yılında 18,020 olacağını öngörürken, bu sayının diğer kanser çeşitleri nedeniyle ölenlerin sayısının %3'ünü oluşturduğunu göstermektedir (Anonymous 1).

Beyin tümörleri, kanserli hücre (malign) özelliği göstererek başka dokulara yayılan tipte veya kanserli olmayan (benign) hücre özelliği göstererek diğer dokulara yayılım göstermeyen tipte olabilmektedir. Buna bağlı olarak beyin tümörleri metastatik ve birincil (primer) olarak sınıflandırılırlar. Birincil beyin tümörlerinin kaynağı beyin hücreleri iken, metastatik beyin tümörlerinin kaynağı vücudun farklı organlarından diğer organ ve dokulara yayılım gösteren kanser hücreleridir (Doolittle 2004).

Merkezi sinir sistemini oluşturan beyin ve omurilikte 120'den fazla tümör çeşidi görülebilmektedir (Anonymous 2). Yetişkinlerde en sık görülen birincil beyin tümör tiplerinden üç tanesi, merkezi sinir sisteminde bulunan glia hücrelerindeki anomalilerle oluşan ve Şekil 1.1a'da görülen *gliom* (glioma), beyin ile omuriliği çevreleyen yapılardan meninks ve dura materde oluşum gösteren Şekil 1.1b'de görülen *meninjiyom* (meningioma) ile hipofiz bezinde oluşan Şekil 1.1c'de görülen *hipofiz* (pituitary) tümörleridir (Cockerham vd. 1998; Larjavaara vd. 2007; Mohammed ve Al-Ani 2021).



Şekil 1.1. Figshare beyin tümör görüntü veri setinde bulunan MR görüntülerinden alınmış örnek tümör çeşitleri: **a)** meninjiyom; **b)** gliom; **c)** hipofiz tümörü (Cheng 2017)

Beyin tümörü şüphesi olan hastalarda tümörlü bölgelerin hızlı ve doğru şekilde tespiti, hastaların yaşam kaliteleri ve tedavi planlamaları açısından oldukça önemlidir

(Muhammad vd. 2020). Beyin tümörleri şekil, boyut, derece, beyinde bulunduğu yer gibi farklı parametrelerle birbirinden ayrılmaktadır (Khan vd. 2020). Bu tümörlerin net şekilde gözlenebilmeleri için genellikle yumuşak doku kontrastı sağlayabilen, birçok düzlemde görüntü oluşturabilen ve girişimsel olmayan Manyetik Rezonans Görüntüleme (MRG) tekniği tercih edilir (Kaur ve Gandhi 2020; Maravilla ve Sory 1986).

Uzman hekimlerin hastanın tıbbi görüntülerinde mevcut olan tümör bölgelerini el yordamıyla belirleme işlemi, uzmanı yormasının yanı sıra hataya açık, zaman alan bir işlem olarak da bilinmektedir (Chahal vd. 2020; Khan vd. 2020). Bu nedenle tıbbi görüntülerde görüntü işleme çalışmaları ile beraber bilgisayar destekli teşhis veya tanı sistemlerinin kullanımı tümör tespit sürecini hızlandırmakta ve doğru tanı koymayı kolaylaştırmaktadır (Chahal vd. 2020; Muhammad vd. 2020).

Günümüzde tümör tespiti ve sınıflandırılması süreçlerinde makine öğrenmesi algoritmalarının bir alt dalı olan derin öğrenme mimarilerinden artan şekilde yararlanılmaktadır (Khan vd. 2020; Rehman vd. 2020). Bu mimariler, yapılarında bulunan çok sayıdaki öğrenme katmanlarıyla giriş verilerinde belirlenen özellikleri detaylı şekilde öğrenmektedir. Bilgisayarlarda paralel işlemci birimlerinin gelişmesi, çok sayıda verinin ulaşılabilir hale gelmesi ve optimizasyon yöntemlerinin geliştirilmesiyle birlikte derin öğrenme mimarilerinin başarısı da gittikçe artmaktadır. Bu mimariler arasında, görüntü sınıflandırma ve tespitinde kullanılan Evrişimli Sinir Ağları, doğal dil işleme problemlerinde kullanılan Tekrarlayan Sinir Ağları (Recurrent Neural Network; RNN) ve genellikle sentetik veri üretimi gibi işlemlerde kullanılan Çekişmeli Üretici Ağlar (Generative Adversarial Networks; GAN) sayılabilir (Cui vd. 2020). Günümüzde derin öğrenme mimarilerinden olan ESA'nın kullanımıyla tıbbi görüntülerde tümör tespit işlemleri daha hızlı yapılabilmektedir (Aslan 2019). Bunun yanında farklı bir görev için eğitilen sinir ağlarının edindiği bilgilerin başka problemler için kullanılabilirdiği transfer öğrenme yöntemiyle, verilerin az olması sorunu veya donanımsal eksiklik gibi problemlerin üstesinden gelinerek, tıbbi görüntüler üzerinde önemli performanslar elde edilebilmektedir (M. A. Khan vd. 2020).

Önerilen bu tez çalışmasında, MR beyin görüntülerinde tümör dokunun tespiti, sınıflandırılması ve bölütlenmesi aşamalarında tanı koyuculara yardımcı olmak üzere derin öğrenme yöntemlerinden olan Maskeli Bölge Tabanlı Evrişimli Sinir Ağı mimarisi (Maskeli B-ESA) kullanılmıştır (He vd. 2017). Maskeli B-ESA, MR beyin görüntüsündeki tümörün bulunduğu bölge için koordinat bilgisi ile beraber tümör tespiti sağlamaktadır. Aynı zamanda mimari tümörlü bölge içerisindeki pikselleri maskeleyerek örnek bölütleme işlemi de yapabilmektedir (Bayram 2020). Bu tez çalışmasında, önceden eğitilmiş yapay sinir ağ mimarilerinin öğrenme bilgileri üzerinden, yani transfer öğrenme yaklaşımı ile halka açık olarak temin edilen MR beyin tümör görüntülerini içeren bir veri seti üzerinden Maskeli B-ESA mimarisinin eğitimi gerçekleştirilmiştir. Maskeli B-ESA mimarisi ve transfer öğrenme yöntemi ile MR görüntüleri üzerinden beyin tümörlerinin tespit, sınıflandırma ve bölütleme işlemleri tek bir çatıda toplanarak uzman kişiler için el yordamıyla yürütülen işlemler tam otomatik hale getirilmiştir.

Maskeli B-ESA mimarisinin eğitimi literatürde sıklıkla mimarilerin eğitiminde kullanılan halka açık Figshare beyin tümör görüntü veri seti ile gerçekleştirilmiştir (Cheng 2017). Tez çalışmasında, veri setindeki tüm görüntülerin ön işlem uygulanmadan

mimari eğitimi ve testinde kullanılması, görüntülerdeki tümörlü bölgelerin transfer öğrenme metodu ile yeni ESA mimari yapıları ile de incelenmiş olması ve literatürdeki tümör tespit, bölütleme çalışmalarına ek olarak sınıflandırma işleminin de yapılması bu çalışmaya özgün değer katmaktadır. Yapılan çalışmanın MR görüntüsü üzerinden otomatik tümör tespit ve bölütleme yaklaşımı ile uzman doktorlara hızlı ve doğru olacak şekilde destek ve yardımcı olabileceği düşünülmektedir.

Tez çalışmasının birinci bölümünde bazı primer beyin tümör çeşitleri, derin öğrenme mimarilerinin kullanım alanları, transfer öğrenme kavramı ve örnek bölütleme işlemi yapan Maskeli B-ESA mimarisi ile ilgili bilgilere değinilmiştir. İkinci bölümde tez çalışmasıyla ilişkili literatürde bulunan çalışmaların genel özetleri verilmiştir. Üçüncü bölümde MR görüntüleme tekniği, beyin tümörleri, derin öğrenme ve derin öğrenme mimarileri ile derin öğrenme tekniğinde kullanılan kütüphane ve programlama dilleri hakkında genel bilgiler bulunmaktadır. Dördüncü bölümde tez kapsamında geliştirilen derin öğrenme modelleriyle gerçekleştirilen işlemlerin sonuçları doğrulama metrikleri vasıtasıyla gösterilmiştir. Beşinci bölümde tez çalışmasında önerilen Maskeli B-ESA modellerinden elde edilen doğrulama metrikleri literatürde Daha Hızlı Bölge Tabanlı Evrişimli Sinir Ağı (DH B-ESA) ve Maskeli B-ESA mimarileriyle yapılan çalışmalarla karşılaştırılmış ve son olarak tez çalışmasında kullanılan derin öğrenme modellerinin pozitif, negatif ve geliştirilebilir yönleri üzerinden tartışılması yapılmıştır.

2. KAYNAK TARAMASI

Günümüzde bilgisayar donanımlarının güçlenmesi ve çok sayıda veriye ulaşma kolaylığı, bir makine öğrenme algoritması olan derin öğrenme yönteminin gelişimini de beraberinde getirmiştir. Aynı zamanda, farklı derin öğrenme mimarilerinden öğrenilen bilginin transfer edilebilmesi de derin öğrenmenin tıbbi alanda kullanımını kolaylaştırarak tıbbi görüntüler kullanılarak lezyon tespiti ve sınıflandırma işlemlerini uzman kişiye yardımcı olacak şekilde yapılabilir hale getirmiştir. Özellikle derin öğrenme mimarilerinden evrişimli sinir ağlarının medikal uygulama alanlarında kullanılabilir olması, gittikçe artan oranda dikkat çeken bir konu olmuştur. Bu bölümde literatürdeki derin öğrenme yöntem önerileriyle MR görüntüleri üzerinden otomatik şekilde beyin tümör tespiti, segmentasyonu ve sınıflandırması ile ilgili son yıllarda yapılan çalışmaların bir özeti sunulmuştur.

Noreen ve ark. 2020 yılında yapmış oldukları çalışmada MR görüntüleri üzerinden beyin tümörünün tespiti ve sınıflandırması için önceden eğitilmiş iki derin öğrenme modelinin (Inception-v3 ve DensNet-201) farklı katmanlarını kullanarak yüksek seviyeli özelliklerin çıkarılması ve birleştirilmesi için bir yöntem önermişlerdir (Noreen vd. 2020). Önerdikleri yöntemde ilk olarak Inception-v3 modelinin farklı modüllerinden elde edilen özellik çıkarımları birleştirilmiştir (Huang vd. 2017; Szegedy vd. 2016). Birleştirilen bu özellikler daha sonra beyin tümör sınıflandırması için softmax sınıflandırıcısına aktarılmıştır. İkinci olarak DensNet-201 modelinin farklı bloklarından alınan özellik çıkarımları birleştirilerek beyin tümör sınıflandırması için softmax sınıflandırıcısına iletilmiştir (Huang vd. 2017). Çalışmalarında 233 hastanın halka açık 3064 adet T1 ağırlıklı-kontrastlı MR görüntüsünden oluşan ve üç farklı tümör çeşidini (meninjiyom, gliom ve hipofiz) içeren Figshare beyin tümörü veri setini kullanmışlardır (Cheng 2017). Veri setindeki hasta MR görüntüleri 512*512 görüntü çözünürlüğüne sahip aksiyel, koronal ve sağıtal düzlemleri içermektedir. Veri setinde 708 örnek gliom tümörü, 1426 örnek meninjiyom tümörü ve 930 örnek hipofiz tümörü bulunmaktadır. Önerilen çalışma için görüntülerin ön işlenmesinde min-max normalizasyon yöntemi kullanılmıştır. Önerilen modellerin eğitiminde, devir sayısı (epoch) 100, öğrenme hızı 0.0001, batch size (yığın boyutu) 20, kayıp fonksiyonu softmax ve optimizasyon algoritması olarak Adaptif moment tahmin (Adaptive moment estimation- Adam) hiper parametrelerini kullanmışlardır. Derin öğrenme modellerinin eğitimi için TensorFlow ve Keras kütüphaneleri kullanılmış ve verilerin %80'i eğitim için, %20'si ise test için ayrılmıştır. Önceden eğitilmiş Inception-v3 modeli, evrişimli katman, aktivasyon katmanı, havuzlama katmanı ve yığın normalleştirme (batch normalization) katmanını içeren 11 adet (A1-A3, B, C1-C4, D, E1, E2) başlangıç modülünden oluşmaktadır. Önerilen yöntemde Inception-v3 modelinin alt katmanlarındaki C, D ve E modülleri kullanılmış ve her bir modül sırasıyla global ortalama havuzlama, dışlama (dropout) ve tam bağlı katmana bağlanmıştır. Modüllerin tam bağlı katmanından çıkarılan özellikler birleştirilmiş ve beyin tümör sınıflandırması için softmax sınıflandırıcısına aktarılmıştır. Çalışmada kullanılan bir diğer yöntem de farklı sayıda evrişim katmanına sahip dört yoğun blok içeren önceden eğitilmiş Densnet-201 modelidir. Özelik çıkarımı için DensNet-201'in alt katmanlarından alt yoğun blok2, orta yoğun blok3 ve son yoğun blok4 kullanılmış ve her bir blok sırasıyla ortalama havuzlama, dışlama (dropout) ve son olarak tam bağlı katmana bağlanmıştır. Tam bağlı katmandan alınan özellikler birleştirilerek beyin tümör sınıflandırması için softmax katmanına iletilmiştir. Önerilen modelin

performans değerlendirmesi için doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1-puan (F1-score) performans ölçütlerinin kullanıldığı yöntemde, Inception-v3 ESA modelinde %99.34 test doğruluğu elde edilirken DensNet-201 ESA modelinde %99.51 test doğruluğu elde edilmiştir.

Chelghoum ve ark. 2020 yılında önerdikleri yöntemde MR görüntüleri üzerinden beyin tümörlerinin sınıflandırılması için transfer öğrenme metodunu kullanmışlardır (Chelghoum vd. 2020). Çalışmalarında kullandıkları önceden eğitilmiş ESA mimarilerinin hedef veri setiyle eğitim sürelerinin azaltılması amaçlanarak, mimarilerin eğitiminde üç farklı devir sayısı önerilmiş ve mimarilerin farklı devir sayılarındaki tümör sınıflandırma doğruluk başarıları değerlendirilmiştir. Veri seti olarak, meninjiyom (708 kesit), gliom (1426 kesit) ve hipofiz (930 kesit) tümörlerinin olduğu artırılmış kontrastlı MR görüntüleri kullanılmıştır (Cheng 2017). Veri seti 233 hastadan alınan 3064 tane üç farklı tümör içeren T1 arttırılmış-kontrastlı MR görüntüsünden oluşmaktadır. Veri setindeki görüntü boyutları 512*512 piksel ve piksel boyutları 49 mm*49 mm'dir. Çalışmalarında MR görüntüleri üzerinden hızlı şekilde özellik çıkarımının olması ve tümörlerin doğru şekilde sınıflandırılması için önceden eğitilmiş ESA mimarilerinden dokuz tanesini (ALexNet, GoogleNet, VGGNet/VGG-16-19, Resnet-18, ResNet-50, Resnet-101, ResNet/Inception-v4 ve SENet) önermişlerdir (He vd. 2016; Hu vd. 2018). Önceden eğitilmiş ESA mimarilerinin tam bağlı katmanlarındaki çıkışları 1000 sınıftan 3 sınıfa değiştirilmiştir. Önerdikleri sınıflandırma model eğitimi Matlab 2019b programı üzerinde gerçekleştirmişlerdir. Çalışmanın veri ön işleme aşamasında, iki boyutlu gri MR görüntülerden oluşan veri setindeki görüntülere normalizasyon işlemi yapılarak Matlab ortamında görüntüler RGB formatına dönüştürülmüştür. Görüntüler, eğitilmiş ESA mimarilerinin giriş katman görüntü boyutlarına göre (AlexNet ve SENet için 227*227 piksel, GooleNet, VGGNet ve ResNet için 224*224 piksel, ResNet-Inception-v2 için 299*299 piksel) yeniden düzenlenmiştir. Veri setinin %60'ı (1836 kesit) eğitim, %40'ı (1228 kesit) ise test için ayrılmıştır. Önceden eğitilmiş ağların hedef veri setiyle tekrar eğitiminde momentum değeri 0.9 olarak belirlenen Stokastik Gradyan İniş (Stochastic Gradient Descent; SGD) optimizasyon algoritması ile ağların öğrenme hızı 0.0001 ve mini-yığın (mini-batch) boyutu 128 olarak belirlenmiştir. ESA mimarilerindeki yeni katmanların ağırlık öğrenme faktörü ve bias değerleri 10 olarak belirlenmiştir. Ağların veri setiyle sırasıyla 25, 50 ve 90 devir sayıları ile eğitimleri gerçekleştirilmiştir. Eğitim süresince ağların performansları her 50 iterasyonda bir doğrulanmıştır. Ağların farklı devir sayılarındaki eğitim sonuçlarına göre en iyi doğruluk başarısına 90 devir sayısında 1953 dakika eğitim süresi için %98.71 doğruluk oranı gösteren VGG-16 ESA mimarisi ile ulaşmışlardır.

Mehrotra ve ark. 2020 yılında yaptıkları çalışmada beyin tümörlerinin iyi huylu (benign) ve kötü huylu (malignant) olarak sınıflandırılabilmesi için transfer öğrenme teknikleri ile derin öğrenme algoritmaları kullanarak yapay zekâ tabanlı bir yaklaşım önermişlerdir (Mehrotra vd. 2020). Beyin tümörü sınıflandırması için AlexNet, GoogleNet, ResNet-50, ResNet-101 ve SqueezeNet gibi önceden eğitilmiş ESA modellerini önermişler ve hedef veri seti eğitimi için transfer öğrenme yaklaşımından yararlanmışlardır (Iandola vd. 2016). ESA modellerinin çıkış katmanında softmax fonksiyonu ile beyin tümörlerinin sınıflandırılması yapılmıştır. Veri setini Kanser Görüntüleme Arşivi (The Cancer Imaging Archive; TCIA) kamu erişim havuzundan temin etmişlerdir (Clark vd. 2013). Kullandıkları veri setinde 20 hastanın glioblastomlu

toplam 696 (224'ü iyi huylu-472'si kötü huylu) T1 ağırlıklı beyin MR görüntüsü bulunmaktadır. Veri setindeki beyin MR görüntüleri jpeg/jpg formatında ve 512*512*1 boyutlarındadır. Bu görüntülerin boyutları 512*512*1 pikselden 225*225*1 piksele küçültülmüş, eğitim seti ve test seti olarak ayrılmadan önce karıştırılarak %70'i eğitim için, %15'i test ve kalanı doğrulama için kullanılmıştır. Veri sayısının artması için MR görüntüleri üzerinde çevirme, yansıtma, döndürme ve tuz gürültüsü ekleme gibi ön işlemler uygulanmıştır. Önerdikleri çalışmada kaynak veri kümesiyle eğitilmiş sinir ağ modellerinin sınıflandırma katmanları ince ayar ile modellerin hedef veri setine bağlı ikili sınıflandırma (iyi huylu ve kötü huylu tümör) yapabilmesi için değiştirilmiştir. Çalışmalarında önceden eğitilmiş ağırlar, Momentumlu Stokastik Gradyan İnişi (Stochastic Gradient Descent with Momentum; SGDM), Ortalama Karakök Yayılımı (Root Mean Square Propagation; RMSProp) ve Adam optimizasyon algoritmaları kullanımıyla eğitilmiştir. Model eğitimi MATLAB R2018a ortamında gerçekleştirilmiştir. Çalışmalarında model başarılarının ölçümü için doğruluk, hassasiyet, duyarlılık, Matthews korelasyon katsayısı (Matthews Correlation Coefficient; MCC), hata oranı (Error Rate), F1-skoru gibi değerlendirme metriklerini kullanmışlardır. Sonuç olarak, ince ayarlı önceden eğitilmiş ESA mimarisi olan Alexnet ile tüm optimizasyon algoritmalarında eğitilmiş diğer ince ayarlı ESA mimarilerine göre %99.04 oranında daha yüksek bir başarı doğruluğu elde etmişlerdir. Önerdikleri Alexnet mimarisinin eğitimi için kullanılan SGDM optimizasyon algoritması ile hem en yüksek doğruluk oranı elde edilmiş hem de en düşük eğitim süresine ulaşılmıştır. Çalışmalarında en kötü eğitim süresi 114 dakika ile GoogleNet, Adam optimizasyon yöntemi ile elde edilmiştir.

Khan ve ark. 2020 yılında yaptıkları çalışmada beyin MR görüntülerini kanserli veya kanserli olmayan şeklinde sınıflandırmak için bir ESA mimari yaklaşımı sunmuşlardır (H. A. Khan vd. 2020). ESA mimarilerinin tanılama başarımlarını kıyaslaması için önceden eğitilmiş VGG-16, ResNet-50 ve Inception-v3 modellerini Navoneel tarafından halka açık olarak sunulan Kaggle platformundan temin ettikleri veri setleri üzerinde değerlendirmişlerdir (Anonymous 3). Gerçek hastalardan alınan 253 beyin MR görüntüleri üzerinde veri artırma ve görüntü işleme tekniklerini kullanarak ESA mimarilerini MR görüntüleri üzerinden sıfırdan eğitmişlerdir. MR görüntüleri üzerinde açık kaynak Canny kenar bulma (Canny Edge Detection) bilgisayarlı görüş algoritmasını kullanarak görüntülerdeki beynin kenarları daha net gösterilebilmiş ve görüntülerdeki siyah bölgeler kırılarak sadece görüntülerdeki beyin bölümü alınmıştır (Canny 1986). Veri setindeki görüntüler üzerinde çevirme (flipping), döndürme (rotation) ve parlaklık (brightness) gibi işlemler yapılarak veri seti artırılmıştır. Önerdikleri ESA model girişinde RGB kanala sahip boyutu 224*224 piksel olarak atırılmış MR görüntülerini kullanmışlardır. Görüntülerden özellik çıkarımı için evrişim katmanları kullanılmış ve evrişim işleminde kullanılan filtre boyutu her evrişim katmanında aynı olmak üzere 3*3 olarak seçilmiş, filtre sayısını farklı evrişim katmanları için 16, 32, 64 ve 128 olarak belirlemişlerdir. Her evrişim katmanından sonra sırasıyla Doğrultulmuş Doğrusal Birim (Rectified Linear Unit; ReLU) aktivasyon fonksiyonu ile maksimum havuzlama (max-pooling) katmanı kullanmışlardır. Önerdikleri modelin beyin MR görüntüleri üzerinden karar etiketi olarak evet (kanserli) ve hayır (kanserli değil) şeklinde sınıflandırma yapması için çıkış katmanında 256 nörona sahip yoğun tam bağlı katmanla beraber softmax sınıflandırıcısını tercih etmişlerdir. Önerdikleri modelin eğitiminde kayıp fonksiyon olarak Cross Entropy (Çapraz Entropi) belirlenirken, optimizasyon

algoritması olarak Adam olarak belirlenmiştir. Veri setinde 185 görüntü model eğitimi için, 48 görüntü doğrulama için ayrılırken model performans değerlendirilmesi amacıyla 20 görüntü test için ayrılmıştır. Çalışmalarında model eğitimi için yığın boyutunu 32 ve devir sayısını 30 olarak belirlemişlerdir. Önerdikleri çalışmada Python programla dili ile Tensorflow ve Keras kütüphanelerini kullanmışlardır. Önerdikleri sıfırdan veri setiyle eğitilmiş ESA mimarisi ile eğitim verilerinde %96 oranında doğruluğa ulaşılmış ve doğrulama veri seti üzerinde %89 oranında doğruluk başarısı elde etmişlerdir. Aynı veri setiyle eğitimlerini gerçekleştirdikleri önceden eğitilmiş VGG-16, ResNet-50 ve Inception-v3 ESA modelleri ile sırasıyla test veri setinde %90, %92 ve %93 oranlarında doğruluk başarısı ile doğrulama veri seti üzerinde %87, %87 ve %83 oranında doğruluk başarısına ulaşmışlardır. Önerdikleri model veri setiyle test edildiğinde %100 oranında doğruluk başarısı elde ederken, VGG-16 %96 oranında, ResNet-50 %89 ve Inception-V3 %75 oranında doğruluk başarısına ulaşmıştır. Çalışmalarında önerdikleri modelin doğruluk başarısı önceden eğitilmiş ağlara göre daha iyi olmasının yanında, devir sayısı başına ortalama eğitim süresi ise (average training time per epoch) önceden eğitilmiş ağlara göre daha azdır.

Bhanothu ve ark. 2020 yılında yaptıkları çalışmada MR görüntüleri üzerinden otomatik beyin tümör bölge tespiti ve tümör sınıflandırması için Bölgesel Evrişimli Sinir Ağı (B-ESA) ve sınıflandırıcı ağı için temel katman olarak VGG-16 ESA mimarisinin kullanıldığı Daha Hızlı Bölgesel Evrişimli Sinir Ağı (DH B-ESA) mimari yaklaşımında bulunmuşlardır (Bhanothu vd. 2020). Çalışmalarında Figshare beyin tümör veri setini kullanmışlardır. Veri setinde gliom (805 kesit), meninjiyom (694 kesit) ve hipofiz (907 kesit) olmak üzere üç çeşit tümörün toplam 2406 tane T1 ağırlıklı-kontrastlı MR görüntüsü yer almaktadır. Görüntüler üzerinde ön işleme olarak min-max normalizasyon işlemi yapılarak .jpg formatına dönüştürülmüştür. Veri setindeki 1924 görüntü eğitim için kullanılırken, 482 görüntü önerilen modelin testi için kullanılmıştır. DH B-ESA mimari yaklaşımı eğitiminde öğrenme hızı 0.01 ve momentum değeri 0.9 olarak ayarlanmış, SGD optimizasyon algoritması kullanılmıştır. Önerdikleri mimarinin eğitimini her devir sayısında 1000 iterasyon olacak şekilde 120 devir sayısında gerçekleştirmişlerdir. Eğitim sonucunda önerdikleri DH B-ESA ağı ile %98,4 oranında eğitim doğruluğuna ulaşmışlardır. Mimarinin testi için 167 gliom görüntü, 143 meninjiyom görüntü ve 172 hipofiz tümörü görüntüsü kullanılmıştır. Önerdikleri modelin testi sonucunda MR görüntüleri üzerinde tümör alanını çevreleyen sınırlayıcı kutu, tümör tipi ve güven skoru parametrelerini elde etmişlerdir. Önerdikleri model maksimum güven skoru için görüntü üzerinde tahmin edilen sınırlayıcı kutulardan her bir görüntüye karşılık tek bir sınırlayıcı kutu seçmektedir. Mimarinin nesneleri algılama doğruluğunu değerlendirmek ve ölçmek için birleşimler üzerinden kesişimi (Intersection over Union- IoU) metriğini hesaplamışlardır. IoU metriğini hesaplarken gerçek görüntü bilgisi ile önerdikleri modelin görüntü üzerinde tahmin ettiği sınırlayıcı kutu bilgisini kullanmışlardır. Önerdikleri DH B-ESA mimari değerlendirmesinde, ortalama hassasiyetlerin ortalaması (Mean Average Precision; mAP) metriği de hesaplanmıştır. mAP hesaplanırken, IoU değeri 0.5'ten büyük ve eşit hesaplanan görüntülerdeki bölge önerileri Doğru Pozitif (True Positive; TP) olarak, diğer bölge önerileri Yanlış Pozitif (False Positive; FP) olarak değerlendirilmiştir. Elde ettikleri toplam doğru pozitif ve yanlış pozitif değerleri için hassasiyet ve duyarlılık ölçme metriklerini hesaplamışlardır. Tümörler için oluşturdukları hassasiyet duyarlılık eğrisinden 0.1 aralıklı 0 ile 1 arasında 11 adet duyarlılık değeri ile bunlara karşılık gelen 11 hassasiyet değeri alınmıştır. Ortalama hassasiyet değerini 11

noktalı interpolasyon yöntemiyle hesaplayarak sırasıyla gliom tümörü için %75.18, meninjiyom tümörü için %89.45 ve hipofiz tümörü için %68.18 olarak bulmuşlardır.

Masood ve ark. 2020 yılında yaptıkları çalışmada beyin tümörünün otomatik olarak doğru lokalizasyon ve segmentasyonu için Maskeli B-ESA derin öğrenme mimari yaklaşımında bulunmuşlardır (Masood vd. 2020). Maskeli B-ESA ile MR görüntüleri üzerinden tümör veya tümör olmayan bölgelerin tahmini üzerinde çalışmışlardır. Önerdikleri yöntemi çevrimiçi olarak sunulan, yapısal karmaşıklık (structural complexity), edinim açısı (acquisition angle), cihazlar, gürültü ve önyargı alan etkisi (bias field-effect) gibi açılardan farklı olan Figshare Beyin Tümörü (Brain Tumor Figshare-BTF) ve Kaggle Beyin Tümörü (Brain Tumor Kaggle-BTK) (Anonymous 3) veri setleri üzerinde değerlendirmişlerdir. BTF veri seti 233 hastadan alınan 512*512 boyutuna sahip 3064 adet T1 ağırlıklı-kontrastlı MR görüntüsü içerirken, Kaggle platformundan alınan beyin tümör veri seti 845*845 boyutuna sahip 155 adet T1-ağırlıklı MR görüntüsü içermektedir. Çalışmalarında ön işleme aşamasında MR görüntülerindeki artefaktların (gürültü, yanlılık alanı (bias field)) iyileştirilebilmesi için medyan filtresi ile seviye ayarlama yöntemini kullanmışlardır. Veri setlerindeki MR görüntülerinin Gerçek Referans (Ground Truth; GT), Görsel Geometri Grubu Görüntü Açıklayıcı (Visual Geometry Group Image Annotator; VIA) aracı kullanarak etiketlemişlerdir (Dutta ve Zisserman 2019). Modelin uygulanmasında Keras ve Tensorflow kütüphanelerini kullanmışlardır. Önerdikleri model çerçevesi sırasıyla özellik çıkarma, Bölge Önerme Ağı (Region Proposal Network; RPN), İlgili Bölge (Regions of Interest; RoI) sınıflandırıcı ve sınırlayıcı kutu regresyonu (Bounding Box Regressor; BBR), son olarak segmentasyon aşamalarından oluşmaktadır. Görüntü üzerinden özellik çıkarımı için Özellik Piramit Ağı (Feature Pyramid Network; FPN) omurgasına sahip ResNet-101 mimarisini önermişlerdir. Model eğitimini COCO veri setiyle önceden eğitilmiş ağırlıkları kullanarak başlatmışlardır (Lin vd. 2014). Veri setine göre model ince ayarı için transfer öğrenmeyi kullanmışlardır. Veri setinin rasgele olarak %70'ini eğitim için %30'unu ise test için ayırmışlardır. Önerdikleri yöntemi, doğruluk, hassasiyet, duyarlılık, Dice Puan (Dice Score - DSC) ve IoU gibi metrikler kullanarak değerlendirmişlerdir. Önerdikleri yöntemle BTF veri seti üzerinde %95.1 ortalama doğruluk elde ederken BTK veri seti üzerinde % 94.6 oranında ortalama doğruluk elde etmişlerdir.

Harish ve Baskar'ın 2020 yılında yaptıkları çalışmada MR görüntüleri üzerinden otomatik olarak tümör tespiti için gelişmiş DH B-ESA ile tümörlerin iyi huylu ve kötü huylu olarak sınıflandırılması için ön eğitilmiş AlexNet modeli kullanımını önermişlerdir (Harish ve Baskar 2020). Çalışmalarında halka açık olarak sunulan bir veri setini ele alarak farklı boyutlardaki tüm görüntüleri derin öğrenme modeli için aynı boyuta getirmişlerdir. Görüntülerin kalitesini iyileştirmek için kontrast artırma işlemi ile Kontrast Sınırlı Adaptif Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization; CLAHE) yöntemini kullanmışlardır (Yadav vd. 2014). Çalışmada DH B-ESA mimarisinin özellik çıkarıcı katmanı olan evrişim katmanı yerine önceden eğitilmiş ResNet-50 mimarisini önermişlerdir. Gelişmiş DH B-ESA model yaklaşımını tümör tespiti için sunmuşlardır. Tümör sınıflandırması için ince ayarlı önceden eğitilmiş AlexNet mimarisi kullanılmıştır. Görüntülerin ön işleminde ve değerlendirmesinde MATLAB 2019b yazılımını kullanmışlardır. Mimarinin eğitimi için SGDM optimizasyon algoritması, öğrenme başlangıç hızı 0.0003 gibi hiper parametrelerin kullanımı önerilmiştir. Sonuç olarak çalışmalarında önerdikleri gelişmiş DH B-ESA

modeli ile beyin tümörü tespit etme doğruluk başarısını artırdığı, AlexNet algoritmasının %99.25 doğruluk oranıyla tespit edilen tümör bölgesinin iyi huylu veya kötü huylu olarak sınıflandırabildiğini rapor etmişlerdir.

Ram ve Gupta'nın 2020 yılında yaptıkları çalışmada gliom tümörünün tespiti için önceden eğitilmiş dört derin öğrenme mimarisi (Alexnet, Resnet-18, Resnet-50 ve Googlenet) yaklaşımıyla ESA tabanlı DH B-ESA mimarisini kullanmayı önermişlerdir (Ram ve Gupta 2020). Model yaklaşımlarını Matlab R2020a sürümünde uygulamışlardır. Kullandıkları veri seti çevrim içi olarak temin edilebilen gliom tümörü için T1-ağırlıklı kontrastlı farklı düzlemlerde (eksenel, koronal ve sağıtal) 1426 kesit MR görüntüsü içeren Figshare beyin tümör veri setidir (Cheng 2017). Veri setinin orijinal hali ".mat" dosya formatında olduğu için görüntüleri önce .png dosya formatında kaydetmişlerdir. Görüntülerin kontrastını Matlab R2020a sürümünün görüntü işleme araç kutusu (image processing toolbox) kullanımıyla iyileştirmişlerdir. Gerçek referans (ground truth; GT) MR görüntü verilerini, Matlab'ın görüntü işleme araç kutusunda mevcut olan görüntü etiketleme (image labeling) uygulamasıyla etiketlemişlerdir. Model eğitiminde SGDM optimizasyon algoritmasını kullanmışlardır. Önerdikleri DH B-ESA'da kullandıkları önceden eğitilmiş dört mimarinin performanslarını hassasiyet, duyarlılık, algılama doğruluğu (detection accuracy) metriklerine dayalı sınırlayıcı kutuları kullanarak değerlendirmişlerdir. ResNet-50 derin öğrenme mimarisi, Alexnet, ResNet-18 ve GooleNet mimarilerine göre daha yüksek ortalama hassasiyet (mean precision) değeri elde etmiştir. Önerdikleri model ile MR görüntüsü üzerinden gliom tümörü %99.9 doğrulukla tespit edilmiştir.

Kaur ve Gandhi'nin 2020 yılında yaptıkları çalışmada patolojik ve normal (normal ve normal olmayan, gliom-meningiyohipofiz) MR beyin görüntülerinin otomatik olarak sınıflandırması için transfer öğrenme yaklaşımıyla önceden eğitilmiş derin ESA mimarilerini (Alexnet, GoogLeNet, VGG-16, VGG-19, Resnet-50, Resnet-101, Inceptionv3 ve InceptionResNetV2) kullanmışlardır (Kaur ve Gandhi 2020). Model yaklaşımlarını üç farklı veri seti (Harvard, Klinik ve Figshare) üzerinden değerlendirmişlerdir. Klinik veri seti (T. Gupta, Gandhi, Gupta, vd. 2017; T. Gupta, Gandhi, & Panigrahi 2017) 200 hastadan alınmış, 250'si normal, 250'si normal olmayan (gliom tümörlerinden etkilenen) 500 MR görüntüsünü içermektedir. Harvard veri setinin üç versiyonu bulunmaktadır. İlk versiyonda gliom tümöründen etkilenen normal olmayan 20 MR beyin görüntüsü ve normal 30 MR beyin görüntüsü bulunmaktadır (Lahmiri 2017). İkinci versiyonda beyin anomaliliklerini içeren normal olmayan 52 MR beyin görüntüsü ile normal 22 beyin MR görüntüsü bulunmaktadır. Üçüncü versiyon beyin anomaliliklerini içeren 140 normal olmayan MR beyin görüntüsü ve normal 20 MR beyin görüntüsünü içermektedir (Nayak vd. 2016). Figshare veri seti, 233 hastanın gliom (1426), meningiyohipofiz (708) ve hipofiz (930) MR beyin tümör görüntülerini içermektedir. Bu görüntüler, gri düzeyden üç kanallı yapıya dönüştürülmüştür. Veri setlerindeki görüntü boyutlarını önceden eğitilmiş ESA mimarisi giriş katman boyutuna göre yeniden boyutlandırmışlardır. Transfer öğrenmeli önceden eğitilmiş ESA modellerini MATLAB 2017b platformunda tasarlamışlar ve model uygulamasını Intel Xeon CPU E3-1225, 3.3 GHz ve 8 GB RAM sistem yapılandırması ile gerçekleştirmişlerdir. Çalışmalarında önceden eğitilmiş tüm ESA mimarilerinin veri setine bağlı sınıflandırması için yalnızca son üç katmanlarını değiştirmişlerdir. Veri setinin %60'ını eğitim için %40'ını test için kullanmışlardır. Transfer öğrenme ile önceden eğitilmiş ağırları SGDM optimizasyon

algoritması ile eğitmişlerdir. Öğrenme hızı 0.0001, maksimum devir sayısı 20 ve mini-yığın boyutu 10 olarak belirlenmiştir. Modellerin performans analizi için duyarlılık, özgünlük, doğruluk, eğri altındaki alan (area under the curve), yanlış pozitif oranı (false positive rate), F-skoru, Mathew Korelasyon (Mathew correlation; MC) değerlendirme metrikleri kullanılmıştır. Sonuç olarak Alexnet modeli, Harvard veri seti versiyonlarının tümünde %100, klinik veri setinde %94, Figshare veri setinde %95.92 oranında sınıflandırma doğruluğu elde etmiştir. Alexnet modelinin test setini doğrulama başarısının, diğer tüm transfer öğrenmeli önceden eğitilmiş ESA modellerinden daha iyi olduğu görülmüştür.

Badža ve Barjaktarović 2020 yılında yaptıkları çalışmada T1 ağırlıklı-kontrastlı MR görüntüleri üzerinden üç tip beyin tümörünün (meninjiyom, gliom ve hipofiz) sınıflandırması için ESA mimarisi önermişlerdir (Badža ve Barjaktarović 2020). Çalışmalarında kullandıkları veri seti, meninjiyom (708 görüntü), gliom (1426 görüntü) ve hipofiz (930 görüntü) tümörlerinin T1 ağırlıklı-kontrastlı MR görüntülerini içeren Figshare veri setidir. Veri setinde, 233 hastanın sağıtal (1025 görüntü), ekstenel (994 görüntü) ve koronal (1045 görüntü) olmak üzere üç farklı düzlemde çekilmiş görüntüleri mevcuttur. Ön işleme adımında veri setindeki görüntüler normalize edilmiş ve görüntülerin boyutları önerilen ESA mimari girişi için 256*256 piksel olarak değiştirilmiştir. Veri setindeki her bir görüntü üzerinde 90 derece döndürme işlemi ile dikey olarak çevirme işlemi yapılarak veri seti üç kat artırılmış ve toplam 9192 görüntü elde edilmiştir. ESA mimarilerini Matlab 2018a sürümüyle geliştirmişlerdir. ESA mimarisi, giriş katmanı, iki ana blok, sınıflandırma bloğu ve çıkış katmanı olmak üzere toplam 22 katmandan oluşan bir yapıdır. Önerdikleri modeli, Adam optimizasyon algoritması, mini-yığın boyutu 16, her iterasyonda veri karıştırma kullanılarak eğitmişlerdir. Glorot başlatıcısı ile evrişim katmanlarının ağırlıklarını başlatmışlardır (Glorot ve Bengio 2010). ESA mimarisini iki farklı 10 kat çapraz doğrulama (kayıt açısından ve konu açısından) ve veri seti (orijinal ve arttırılmış) kombinasyonu ile değerlendirmişlerdir. Sonuç olarak kayıt açısından 10 kat çapraz doğrulama ile arttırılmış veri küme kombinasyonu %96.56 oranında en iyi test doğruluğu elde etmiştir.

Rehman ve ark. 2019 yılında yaptıkları çalışmada beyin tümörlerinin sınıflandırması ve otomatik olarak tespiti için transfer öğrenme yöntemleri ile önceden eğitilmiş derin ESA mimarilerini (AlexNet, GoogLeNet ve VGGNet) kullanmışlardır (Krizhevsky vd. 2012; Liu ve Deng 2015; Rehman vd. 2020; Szegedy vd. 2015). Çalışmada, 233 hastadan alınan T1 ağırlıklı-kontrastlı, üç farklı tümörün (meninjiyom (708 kesit), gliom (1426 kesit) ve hipofiz tümörü (930 kesit) toplam 3064 MR görüntüsünü içeren halka açık veri setini kullanmışlardır. Önerilen yöntemde, yüksek çözünürlüklü, daha iyi kontrastlı MR görüntülerinin eldesi için veri ön işlem aşamasında kontrast germe algoritmasını kullanmışlardır. Bununla beraber önceden eğitilmiş ESA modellerinin verimli eğitimi için görüntüler üzerinde 90, 180, 270 derece açılarla döndürme işlemi ile dikey ve yatay yönlerden aynalama işlemleri yapılarak veri sayısının arttırılması sağlanmış ve ESA modellerinin hedef veri seti özelliklerini aşırı ezberleme (over-fitting) durumunun önüne geçilmek istenmiştir. Veri setinin %70'ini eğitim, %15'ini doğrulama ve %15'ini de test için kullanmışlardır, Veri setindeki MR görüntülerinin (hedef) özellik çıkarımı için ImageNet veri setiyle önceden eğitilmiş AlexNet, GoogLeNet ve VGGNet mimarileri üzerinde ince ayar (fine-tuning) ve dondurma (freeze-ağırlıkların güncellenmemesi) olmak üzere iki transfer öğrenme

teknikği uygulanarak beyin tümör tespiti ve sınıflandırmasında mimarilerin performansları kıyaslanmıştır (Russakovsky ve Fei-Fei 2010). Çalışmalarında Caffé kütüphanesi sürüm 7'yi kullanmışlardır. Önceden eğitilmiş ESA mimarilerinin 1000 kategorili sınıflandırma için oluşturulmuş çıkış katmanı ince ayar işlemiyle veri setinin sahip olduğu üç sınıfa (meninjiyom-gliom-hipofiz) göre nöron sayısı değiştirilmiştir ve son katmanda sınıflandırıcı olarak log-tabanlı softmax kullanılmıştır. İnce ayarlı VGG-16 mimarisi beyin tümörlerinin tespiti ve sınıflandırılmasında diğer ince ayarlı mimarilerden daha yüksek bir başarı elde ederek test setinde %98.69, doğrulama setinde %98.79 ve eğitim setinde %99.02 doğruluk göstermiştir. Çalışmalarında son olarak önceden eğitilmiş mimarilerden AlexNet ve VGG16 mimarilerinin bazı evrişimli ve tam bağlı katmanları ile GooleNet'in Inception katmanları dondurulmuş, bu katmanlardan alınan özellik çıkarımları özellik vektörü haline getirilerek tümör sınıflandırması için doğrusal sınıflandırıcı olan Destek Vektör Makinesine (Support Vector Machine; SVM) iletilmiştir (Cortes ve Vapnik 1995). Transfer öğrenme tekniklerinden biri olan dondurma işleminde GoogleNet mimarisinin başlangıç-4 çıktı katmanından alınan özellikler ile yapılan sınıflandırma sonucuna göre %95.77 oranında en yüksek doğruluk elde edilmiştir.

Ismael ve ark. 2019 yılında yaptıkları çalışmada Kalıntı Sinir Ağı-50 (Residual neural network-50; ResNet-50) mimarisini kullanarak beyin tümörlerinin yüksek doğrulukla sınıflandırılabilmesi için gelişmiş bir derin öğrenme yaklaşımında bulunmuşlardır (Ismael vd. 2020). Önerdikleri modelin eğitiminde ve değerlendirilmesinde halka açık olan Figshare beyin tümör veri setini kullanmışlardır. Kullandıkları veri setinde 3064 tane Matlab veri formatında (.mat) dosya bulunmaktadır. Bu dosyaların içeriğinde, hasta ID'si, tümörlü MR beyin görüntüsü, görüntü tümör etiketi (1- meninjiyom, 2-gliom, 3-hipofiz), görüntüdeki tümör bölge sınırları gibi bilgiler bulunmaktadır. Çalışmalarında veri setindeki .mat formatı içinde depolanan verileri okuyabilmek için oluşturdukları Python kod bloklarıyla beraber h5py kütüphanesini kullanmışlardır. Veri setindeki görüntüleri gerçek boyutları olan 512*512 olarak kaydetmişler ve ilgili tümör çeşidi klasörüne yerleştirmişlerdir. Görüntülerin hasta kimlikleri (hasta-ID) de .mat dosyaları içinden çekilmiştir. Çalışmalarında veri setinin % 80'inini model eğitimi için, % 20'sini ise model validasyonu için ayırmışlardır. Veri setini ayırmada iki yaklaşımda bulunmuşlardır. İlk olarak görüntülerin hasta id'lerine dikkat edilmiş yani aynı hasta hem eğitim veri setinde hem de validasyon veri setinde kullanılmayacak şekilde ayırma işlemi yapılmış ve bu işleme *hasta düzeyinde yaklaşım* adını vermişlerdir. İkinci olarak görüntülerin rasgele şekilde eğitim ve validasyon olarak ayırma işlemi düşünülmüş ve bu işleme de *görüntü düzeyinde yaklaşım* adını vermişlerdir. Çalışmalarının veri setini ön işleme basamağında görüntüleri merkezde 450*450 olarak kırpılmışlardır. Modelin eğitim başarısının ve veri sayısının artırılması için veri setindeki görüntüler üzerinde yatay ve dikey çevirme (horizontal and vertical flips), döndürme (rotation), kaydırma (shifting), yakınlaştırma (zooming), ZCA beyazlatma (ZCA whitening), kırpma (shearing), ve parlaklık manipülasyonu (brightness manipulation) gibi veri artırma tekniklerini kullanmışlardır. Önerdikleri model 50 katmana sahip, değiştirilmiş (varyant) Resnet-50 mimarisidir ve 3 tümör çeşidinin sınıflandırması için bu mimarinin son katmanını değiştirmişlerdir. Çalışmalarında önerdikleri modelin eğitimi için 500 devir sayısı ile öğrenme hızı için 0.00001, yığın boyutu için 32, optimizasyon algoritması olarak Adam'ı önermişlerdir. Modellerini TensorFlow 1.13 ile Keras 2.2.4 kütüphanesini kullanarak Python 3.6'da uygulamışlar ve önerdikleri modelin eğitiminde her devir sayısı ortalama 30 saniye sürmüştür. Önerdikleri

modelin performans başarımlarını ölçütü için doğruluk, hassasiyet, duyarlılık, F1-skoru ve dengeli doğruluk (balanced accuracy) gibi ölçütler hesaplanarak modelin başarımları değerlendirilmiştir. Model yaklaşımlarının MR görüntüleri üzerinde beyin tümör sınıflandırmasında hasta düzeyinde yaklaşım ile %97 oranında doğruluk elde edilirken görüntü düzeyinde yaklaşım ile %99 oranında doğruluk elde etmişlerdir.

Talo ve ark. 2019 yılında yaptıkları çalışmada MR beyin görüntülerinin normal veya normal olmayan olarak otomatik sınıflandırma işlemi için transfer öğrenme yöntemli ResNet-34 ESA mimari yaklaşımını kullanmışlardır (Talo vd. 2019). Çalışmalarında kullandıkları veri setini Harvard Medical School web sitesinden temin etmişlerdir. Veri setindeki görüntüler T1 ağırlıklı beyin MR görüntüleri olup eksenel düzlemde 256*256 piksel boyutunda olup eğitim ve doğrulama işlemleri için toplam 613 görüntü kullanılmıştır. Bu görüntülerin 27'si normal iken 513 görüntü ise anomali içermektedir. Anormal MR beyin görüntüleri 40 farklı denekten alınırken, normal beyin MR görüntüleri 2 denekten alınmıştır. Veri setindeki normal olmayan görüntüler serebrovasküler (cerebrovascular), neoplastik (neoplastic), dejeneratif (degenerative) ve inflamatuvar (inflammatory) hastalık türlerini içermektedir. Önerdikleri yaklaşımda ön eğitilmiş Resnet34 modelinin sadece evrişim katmanları ile havuzlama katmanları kullanılmış ve veri setindeki görüntüler ile eğitilen mimarinin yoğun katmanı, normal ve normal olmayan şeklinde sınıflandırma için değiştirilmiştir. Mimari yaklaşımlarının son katmanında sınıflandırma için log-softmax aktivasyon fonksiyonunu kullanmışlardır. Mimarilerinde gizli katmanlardaki nöronlarda ReLU aktivasyon fonksiyonu kullanılmıştır. Evrişimli katmanlarda 3*3 boyutlu filtreler görüntü üzerinde özellik çıkarımı işlemlerinde 2 adım kaydırma ile uygulanmıştır. Mimari eğitimi için veri artırma, en uygun (optimal) öğrenme hızı bulucu, ince ayar gibi derin öğrenme tekniklerini kullanmışlardır. ResNet mimari yaklaşımının son katmanında yaptıkları değişikliklerle beraber mimarinin evrişim tabanının bazı parametrelerinde de ince ayar yapılmıştır. Önerdikleri mimarinin eğitimi için beyin MR görüntülerinde yatay çevirme (horizontal flipping), döndürme (rotating) ve %10 oranında yakınlaştırma (zooming) işlemleri uygulanarak veri setini artırmışlardır. Mimarilerinde Adam optimizasyon algoritmasını kullanmışlardır. Önerdikleri ağırlık performans değerlendirmesi için 5 kat çapraz doğrulama yapmışlardır. Veri setinin %80'nini eğitim için %20'sini ise doğrulama için kullanmışlardır. Önerdikleri modeli Python ile açık kaynak fast-ai çerçevesi ve Pytorch kütüphanesi ile uygulamışlardır. Model performans değerlendirmesini; modelin başlangıç eğitimi, veri artırma-optimal öğrenme hızı bulucu ile Yeniden Başlatmalarla Stokastik Gradyan İnişi (Stochastic Gradient Descent with Restarts; SGDR) ve ince ayarlı model eğitimi (evrişim katmanı ve yoğun katmanlarını beraber eğitme) olmak üzere 3 aşamada sunmuşlardır. Modelin performans değerlendirme 1. Aşamaları olan başlangıç eğitiminde evrişim tabanını dondurarak sadece mimarinin son yoğun katmanını eğitmişler ve önerdikleri modelin beş kat doğrulaması ile ortalama %97.87 oranında doğruluk değeri elde etmişlerdir. Sundukları 2. Aşama olan veri artırma-optimal öğrenme hızı bulucu ve SGDR kullanımıyla model yeniden eğitilmiş ve modelin beş kat doğrulaması ile %97.87 model doğruluğuna ulaşmışlar ve eğitim ile doğrulama hata seviyesi 1. Aşama'ya göre azalmıştır. 3. Aşamada ise öğrenme hızını ilk katmanlar (0.00001), orta katmanlar (0.0001) ve yoğun katmanlara (0.00001) göre farklı değerlerde ayarlayarak evrişim katmanı ve yoğun katmanların beraber eğitimini gerçekleştirmişler, önerdikleri modelin beş kat çapraz doğrulaması ile %100 doğruluk başarısına ulaşabilmişlerdir.


Kaldera ve ark. 2019 yılında yaptığı çalışmada gliom ve meninjiyom beyin tümörlerini içeren MR görüntülerinin tam otomatik sınıflandırılması ve segmentasyonu için derin öğrenme yaklaşımında bulunmuşlardır (Kaldera vd. 2019). Sınıflandırma için bir ESA mimarisi önerirken, bölütleme için DH B-ESA mimarisini önermişlerdir. Model eğitimi için Figshare veri setini kullanmışlardır (Cheng 2017). Veri setindeki T1 ağırlık-kontrastlı beyin MR görüntülerinden gliom (138 kesit) ve Meninjiyom (119 kesit) görüntülerini tercih etmişlerdir. Kullandıkları veri setini eğitim (training), doğrulama (validation) ve test (testing) için üçe ayırmışlardır. Veri setindeki beyin MR görüntü boyutlarını 512*512 pikselden, 128*128 piksele çevirmiş, görüntü piksel değerlerini 0-255 değerlerinden 0-1 aralığına çekerek görüntüde normalizasyon işlemi uygulamışlardır. Beyin MR tümör görüntülerinin sınıflandırması için önerdikleri yöntemin eğitimi için gliom ve meninjiyom görüntülerini içeren toplam 218 görüntüden yararlanılmış ve yöntemin test işlemleri için eğitim veri setinden farklı bir veri seti kullanılmıştır. Önerdikleri model mimarisi sırasıyla ön işleme ile sınıflandırma için ESA mimarisini ve sadece meninjiyom tümör segmentasyonu için DH B-ESA mimarisini içermektedir. Çalışmalarında mimarilerinin ilk bölümünde 2 katmanlı ESA mimari modeli önermişler. Modellerinde evrişim işlemleri için sayıları sırasıyla 20 ve 10 olan 3*3 boyutlu filtreler belirlenmiş, aktivasyon fonksiyonu olarak ReLU ve pencere boyutu 2*2 olan 2 adet maksimum havuzlama (maxpool) katmanı kullanılmıştır. Sınıflandırma işlemi için tam bağlı bir katman kullanılmış ve çıkış katmanını tümörün gliom veya meninjiyom olarak sınıflandırması için 2 nöron olarak değiştirilmiştir. Önerilen yaklaşım için Python Tensorflow Keras kütüphanelerinden yararlanılmıştır. Model testinde 15 adet meninjiyom beyin MR görüntüsü ve 21 gliom beyin MR görüntüsü kullanılmıştır. Model, meninjiyom tümörünü %100 doğruluk oranıyla sınıflandırırken, gliom tümörünü %87.5 doğruluk oranıyla sınıflandırmıştır. DH B-ESA’da görüntüden özellik çıkarımı için Imagenet veri setiyle önceden eğitilmiş ESA modeli ile görüntüden elde edilmiş özellik haritası üzerinde tümörün olabileceği bölge önerileri için RPN kullanılmıştır. DH B-ESA mimarisi çıktı olarak görüntü üzerinde sınırlayıcı kutu ile meninjiyom tümörü olma olasılığı değeri olan güven düzeyini vermektedir. DH B-ESA eğitimi için 110 meninjiyom görüntüsü kullanılırken, doğrulama için 9 meninjiyom tümör görüntüsü kullanılmıştır. Meninjiyom tümör segmentasyon yaklaşımlarında %94.6 güven düzeyi elde etmişlerdir.

Avşar ve Salçın 2019 yılında yaptıkları çalışmada üç farklı tümörün MR görüntüleri üzerinden (gliom, meninjiyom ve hipofiz) tespiti ve sınıflandırması için DH B-ESA derin öğrenme mimarisini kullanmışlardır (Avşar ve Salçın 2019). Çalışmalarında 233 hastanın 3064 adet T1 ağırlıklı 512*512 görüntü çözünürlüğüne sahip üç farklı tümör için MR görüntüsünü içeren halka açık Figshare veri setini kullanmışlardır. Veri setindeki tümör bölgelerini etiketlemek için grafiksel görüntü açıklama aracı olan LabelImg kullanmışlar ve açıklamaları ImageNet tarafından kullanılan format olan PASCAL VOC formatında XML dosyaları olarak kaydetmişlerdir (Anonymous 4). Çalışmalarında veri setinin %80’nini (2452 görüntü rastgele seçilerek ve her tümör çeşidinden aynı oranda olacak şekilde) DH B-ESA model eğitiminde ve kalan %20’lik (612 görüntü) görüntü setini ise modelin testi için kullanmışlardır. DH B-ESA modeli Tensorflow kütüphanesi ve Python programlama dilinden yararlanılarak uygulanmıştır. Çalışmalarında model eğitimi için öğrenme hızını 0.0002, momentum sabitini 0.9, yığın boyutunu (batch size) 1 ve iterasyon sayısını 150.000 olarak belirlemişlerdir. Önerdikleri çalışmada modelin çıktı katmanındaki minimum softmax olasılık değerini üç farklı eşik değeri için (0.8, 0.66

ve 0.5) önermişler ve modelin farklı eşik değerlerinde MR görüntüleri üzerinden tümör etiketi sınıflandırmasındaki performans değişimlerini doğruluk, hassasiyet, duyarlılık, özgünlük ve F-skoru gibi metriklerle değerlendirmişlerdir. Çalışmalarında karar eşik değerinin düşük seçilmesine bağlı olarak mimarinin sınıflandırılammış tümör bölge önerisi sayısının azaldığı karmaşıklık matrisiyle gösterilmiştir. Önerdikleri çalışmada %91.66 oranında sınıflandırma doğruluğu elde etmişlerdir.

Bu tez çalışmasında MR görüntüleri üzerinden beyin tümörlerinin tespiti, sınıflandırılması ve segmentasyonu için bir derin ESA mimari omurgasını içeren Maskeli B-ESA tekniği kullanılmıştır. Literatür incelemelerinde MR görüntüleri üzerinden beyin tümör türlerinin Maskeli B-ESA mimarisi ile sınıflandırma, tespit ve segmentasyon çalışmalarının görece az olduğu görülmüştür. Bu nedenle hazır görüntü setinden (Cheng 2017) elde edilen beyin tümör görüntülerinin önceden eğitilmiş farklı (ResNet-50 ve ResNet-101) mimari omurgaları ve farklı başlangıç ağırlıkları ile (COCO ve ImageNet) önerilen Maskeli B-ESA mimarileri üzerinden beyin tümörlerinin sınıflandırma, tespit ve bölütlemesi gerçekleştirilmiş ve literatürdeki çalışmalarla çalışmada elde edilen sonuçlar kıyaslanmıştır.

Beyin veya beyin çevresinde bazı hücrelerin kontrolsüz çoğalması sonucunda beyin tümörleri oluşmaktadır (Polat ve Güngen 2021). Beyin tümörleri beynin kendi dokusunda oluşursa *birincil beyin tümörleri*, insan vücudunun farklı organlarından kökenli olarak beyinde oluşum gösterirse *ikincil (metastatik) beyin tümörleri* olarak adlandırılır (Saranya vd. 2021). Birincil ve ikincil beyin tümörlerinin oluşturduğu 150’den fazla farklı beyin tümör çeşidi bulunmaktadır (Mohammed ve Al-Ani 2021). Beyin tümörleri iyi huylu (benign; kanser hücresi bulunmayan) ve kötü huylu (malign; kanser hücresi bulunan) olarak sınıflandırılmaktadır. İyi huylu tümörler çevre dokulara yayılım göstermeden Şekil 3.3a’da gösterildiği gibi bulunduğu yerde yavaş bir büyüme gösterir. Kötü huylu tümörler ise Şekil 3.3b’de gösterildiği gibi hızlı şekilde büyüme ve çevre dokulara yayılma eğilimi gösterir. Ayrıca kanserli tümörler lenf ve kan dolaşımıyla vücudun diğer organlarında da görülebilmektedirler. Tümörlerin beyindeki konumu, büyüme hızı ve yayılma hızı beynin işleyiş mekanizmasını farklı şekillerde etkilemektedir (Saranya vd. 2021).




Şekil 3.3. MR görüntülerinde beyin tümörlerinin sınıf temsili: **a)** iyi huylu tümör; **b)** kötü huylu tümör (Saranya vd. 2021)

3.1.2. Prevelans (Yaygınlık)

Amerikan Kanser Derneği, çocukları ve yetişkinleri konu alan bir bildirisinde, 2021 yılı içinde Amerika Birleşik Devletleri’ndeki yaklaşık 24,530 kişide (13,840 erkek ve 10,690 kadında) malin tümör teşhisine rastlanacağı tahmininde bulunmuştur. Aynı bildiride merkezi sinir sistemi tümörlerinden dolayı yaklaşık 18,600 kişinin (10,500 erkek ve 8100 kadın) öleceği bildirilmiştir (Anonymous 6). Merkezi sinir sistemi tümörlerinin küresel prevalansı 5 yılda yaklaşık olarak 771,110 vakadır. Tüm merkezi sinir sistemi tümörlerinin küresel insidansı 100,000 kişi-yıl başına 3.9’dur. Tüm kanserlerin %1.7’sini oluşturan (Reynoso-Noverón vd. 2021) birincil beyin tümörleri ise tüm merkezi sinir sistemi tümörlerinin %50-75’ini oluşturur. Çoğunluğu deride ve iç organları kaplayan dokularda oluşan metastatik tümörler (carcinoma metastases) olmak üzere ikincil beyin tümörleri de tüm merkezi sinir sistemi tümörlerinin %25-50’lik kısmını oluşturur (Yapıcıer 2020). Birincil intrakraniyel tümörlerden menenjiyom, gliom ve hipofiz tümörleri Şekil 3.4’te görüldüğü gibi en sık görülen tümör çeşitleridir (Nilsson vd. 2018).

Merkezi sinir sistemi tümörleri yetişkinlerde, bebek ve çocuklara göre daha nadir görülmektedir. Yetişkinlerde en sık görülen beyin tümörleri meninjiyom (meningioma), gliom (glioma) ve hipofiz adenomuyken (pituitary adenoma), çocuklarda en yaygın görülen tümörler pilositik astrositomlar (pilocytic astrocytomas) ve medulloblastomalar (medulloblastomas)'dır (McNeill 2016; Yapıcıer 2020).



Şekil 3.4. Birincil beyin tümörlerinin dağılımı (sol) ile gliomların alt tiplerinin (sağ) dağılımlarının gösterimi (Nilsson vd. 2018)

3.1.3. Semptomlar ve bulgular

Beyin tümör semptomları tümörün bulunduğu konuma göre değişebilmektedir. Kişilerdeki genel tümör semptomları baş ağrıları, nöbetler, zihinsel (hafıza problemleri) ve davranışsal (kişilik değişimi) değişimler, duylarda (görme, duyma ve koku) ve konuşmada problemler, vücudun bir tarafından felç veya ilerleyici zayıflık, bulantı veya kusma, yorgunluk gibi problemlerdir (Cahill vd. 2012).


3.1.4. Beyin tümör çeşitleri ve evreleri

Dünya Sağlık Örgütü, sinir sistemi tümörlerini histolojik özelliklerine göre Evre I, Evre II, Evre III, Evre IV olmak üzere kategorileştirmiştir. Evre I sınıfındaki tümörlerde yavaş büyüme, kanserli hücre olmama durumları görülür ve bu sınıfa ait tümörü olan kişilerde sağ kalım süresi uzundur. Evre II sınıfındaki tümörlerde yavaş büyüme görülür, fakat daha yüksek dereceli tümörler olarak tekrarlanabilirler. Bu tümörler kanserli veya kanserli olmayan yapıda olabilmektedir. Evre III sınıfındaki tümörler kanserlidir, kötü huylu ve genellikle daha yüksek dereceli tümörler olarak tekrarlama gösterirler. Evre IV sınıfındaki tümörler ise hızla çoğalır ve çok agresif kötü huylu (kanseri) yapı gösterirler (A. Gupta ve Dwivedi 2017).

Gliomlar (Şekil 3.5) belirli bir tümör ismi olmamakla birlikte sinir hücreleri ve kan damarları dışındaki beyin dokularında (glia hücrelerinde, astrositomalar (glioblastomalar dahil), oligodendrogliomalar ve ependimomlar gibi) oluşan yaygın şekilde kötü huylu tümörlerdir (McNeill 2016). Gliomların teşhislerinde Dünya Sağlık Örgütü tarafından hücrelerin histolojik bilgilerinin I'den IV'e evrelenen sistem kullanılır (Anaraki vd. 2019).

Meninjiyomlar (Şekil 3.5), beyni ve omuriliği çevreleyen meninks doku tabakalarında görülen genellikle iyi huylu tümörler olup yetişkinlerde en sık görülen birincil beyin tümörleridir (Alqudah vd. 2020; Badža ve Barjaktarović 2020; McNeill 2016).

Hipofiz tümörleri (Şekil 3.5), hipofiz bezi bölgesinde oluşum gösterir ve genel olarak iyi huylu tümörlerdir. Ancak büyüdüklerinde çevrelerindeki yapıları baskılayabilmekte veya bazı hormonların fazla üretimine neden olabilmektedirler. Bu nedenlerle meninjiyomlara göre daha ciddi sağlık sorunlarına neden olabilmektedir (Alqudah vd. 2020; Anaraki vd. 2019).



Şekil 3.5. Birincil beyin tümörlerinin (gliom, meninjiyom, hipofiz) sırasıyla aksiyel (sol), koronal (orta) ve sajital (sağ) düzlemlerdeki MR görüntüleri

3.2. Beyin Tümörlerinin Tanısında Kullanılan Görüntüleme Teknikleri

3.2.1. Giriş/Genel teknikler


Beyin tümörlerinin erken teşhis edilebilmesi hastalar için uygun tedavinin planlanması, sağ kalım oranlarının artması ve yaşam kaliteleri için çok önemlidir. Tanısal amaçla faydalanılan medikal görüntüleme tekniklerinin tümör teşhisi, hasta tedavi planlanması, hastalığın takibi ve seyri, tedavi sonrası analizler gibi süreçlerde kullanımı çok önemlidir (Nilsson vd. 2018; Zhang vd. 2020). Beyin tümörlerinin tanılmasında (tümör tipi, şekli, boyutu, lokalizasyonu vb.) Beyin tümörlerinin tanılmasında (tümör tipi, şekli, boyutu, lokalizasyonu vb.) Bilgisayarlı Tomografi (Computed Tomography; CT), Tek-Foton Emisyonlu Bilgisayarlı Tomografi (Single-Photon-Emission Computed Tomography; SPECT), Pozitron Emisyon Tomografi (Positron Emission Tomography; PET), Manyetik Rezonans Spektroskopisi (Magnetic Resonance Spectroscopy; MRS), Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging; MRI) gibi medikal

görüntüleme tekniklerinden yararlanılmaktadır (Díaz-Pernas vd. 2021; Işın vd. 2016).

MR ve CT cihazları beynin farklı bölgelerini tarayarak beyindeki lezyonların tespitinde kullanılan anatomik kesitsel görüntüleme yöntemlerinden ikisidir (Selvapandian vd. 2020; Zhang vd. 2020). MR cihazları tarama için radyo dalgaları ve yüksek manyetik alandan faydalanırken, CT cihazları iyonize edici özellikteki x-ışınlarını kullanır (Selvapandian vd. 2020). Beyin tümörlerinin görüntülenmesinde, yumuşak doku kontrastının iyi olması, çoklu-sekanslarda görüntü oluşturulabilmesi, görüntüde daha düşük artefakt gibi üstünlükleriyle standart görüntüleme yöntemi MR cihazlarıdır (Nilsson vd. 2018; Schillaci vd. 2007; Zhang vd. 2020). CT cihazları ise erişim kolaylığının fazla olması, hızlı görüntü eldesi ve hasta için MR cihazının tehlikeli olduğu durumlar (protez, kalp pili vb.) gibi nedenlerle beyin tümörü görüntülenmesinde çoğunlukla ilk olarak başvurulanan yöntemdir. Ayrıca CT görüntüleme, kafatası (skull) lezyonları, kireçlenme (calcifications) ve hiper akut kanama gibi durumları belirlemede MR görüntülemeye göre daha üstündür (Minniti vd. 2019).

Nükleer tıp görüntüleme teknikleri olan PET ve SPECT’de, metabolik ve fonksiyonel bilgi sağlama özellikleriyle beyin tümörünün malinite derecesini belirlemede ve tümör teşhisinde yardımcı ek bilgiler sunan görüntüleme yöntemlerindendir (Schillaci vd. 2007). PET (Şekil 3.6) ve SPECT genel görüntüleme prensiplerinde hastaya uygulanan radyoizleyicinin (sırasıyla, pozitron yayan radyo izotop ve gama yayan radyo izotop) dokudaki fizyolojik dağılımından yararlanılır (Zhang vd. 2020); (Anonymous 7). PET, SPECT’e göre daha iyi kontrast ve uzamsal çözünürlük sağlar (Anonymous 7).

Medikal görüntülemede detaylı anatomik bilgi sağlayan cihazlarla (CT-MR) metabolik ve fonksiyonel bilgiyi sağlayan cihazların (PET-SPECT) hibrit olarak (SPECT-CT, SPECT-MRI, PET-CT ve PET-MRI) kullanıldığı sistemler de günümüzde kliniklerdeki yerini almıştır. Bu sistemlerle daha ayrıntılı anatomik bilgi elde edilerek görüntüde tümör bölge sınırlarının daha iyi gözlenebilmesi ve daha faydalı bir tedavinin planlanması sağlanabilmektedir (Zhang vd. 2020).




Şekil 3.6. Kontrast-artırılmış MRG (üst sıra) ve çoklu PET izleyicilerin kullanımıyla glioblastoma beyin tümörünün konumunun görüntülenmesi: **(a)** [18F]-2-fluoro-2-deoxy-D-glucose ([18F]FDG); **(b)** O-(2-[18F]-fluoroethyl)-L-tyrosine ([18F]FET), **(c)** [18F] Fluorocholine; **(d)** 1-(2-Nitro-imidazolyl)-3-[18F]fluoro-2-propanol ([18F]FMISO); **(e)** 3'-deoxy-3'-[18F]fluorothymidine ([18F]FLT) (Pruis vd. 2020).

3.2.2. MR görüntülemenin ilkeleri

Manyetik Rezonans Görüntüleme (MRG), çok iyi yumuşak doku kontrastı sağlaması nedeniyle merkezi sinir sistemi (beyin, omurilik) hastalıklarının tespitinde, kas-iskelet sistemi ve batin içi organların görüntülenmesinde tercih edilen, girişimsel olmayan bir görüntüleme tekniğidir (Liu vd. 2014; Valverde vd. 2021). MRG tekniği, canlı dokuların yapısal özelliklerinin çok yüksek çözünürlükte kapsamlı görünümünü oluşturur (Revett 2011). MR cihazı görüntü oluştururken temelde dokulardaki hidrojen atomu çekirdeklerinin doğal manyetik özelliğini ve bu atom çekirdeklerinin güçlü bir manyetik alana maruz bırakılmasıyla, belli frekanstaki radyo frekans sinyallerinin uygulanmasına (elektromanyetik radyasyonu) bağlı olarak gözlenen değişimlerin algılanarak görüntü oluşturulması prensibini kullanır (Akar ve Ünlü 2014; Revett 2011).

3.2.2.1. MRG çalışma prensibi ve görüntü oluşumu


MRG, insan vücudunda çok miktarda bulunan tek protonlu (%60-70 oranında su (H₂O) ve yağ molekülleri), doğal manyetik özelliğe sahip (manyetik momentum) Hidrojen atomu çekirdeğinin elektromanyetik radyasyon (Radyo Frekans sinyali; RF sinyali) ile etkileşimini temel alır (Akar ve Ünlü 2014; Chrysikopoulos 2009). Bu atomun çekirdeği (proton) spin özeliğinden dolayı etrafında bir manyetik alan indüklemesi oluşturur ve bu etki eşit güçteki kuzey/güney eksenini bir manyetik moment ile ifade edilebilir. Şekil 3.7’de görüldüğü gibi manyetik moment bir okla ifade edilirken ok yönü manyetik momentin hizalanma yönü ve okun uzunluğu ise manyetik momentin büyüklüğü (manyetik alan şiddeti) olarak ifade edilmiştir (Westbrook ve Talbot 2018). Hidrojen, güçlü MR sinyalleri üretebildiği için klinik MRG’de en yararlı çekirdektir (Chrysikopoulos 2009).



Şekil 3.7. Hidrojen çekirdeğinin manyetik momentini (Westbrook ve Talbot 2018)

MR cihazında görüntü oluşumu için ilk olarak RF sinyalini emebilecek ve uyarılma enerjisini geriye salacak bir ortam ve görüntü oluşturmaya yetecek konsantrasyonda hidrojen atomu içeren (küçük manyetik çekirdekler) canlı dokulara ihtiyaç vardır. Uygulanan bir harici manyetik alandan (B₀) canlı dokulardaki çoğu Hidrojen atomunun çekirdeği etkilenir ve spin yönelimleri (manyetik moment) B₀’ın manyetik eksenine paralel (bazı zıt yönde) olacak şekilde hizalanır. Manyetik alanın bir diğer etkisi de önceden düzensiz salınım gösteren hidrojen atomu çekirdeklerinin

manyetik alan şiddet değerine bağlı olan Larmor frekansı ile salınım-yalpalaması (presesyon) yapmalarını sağlamasıdır. Manyetik alan yönünde (B_0) hizalanan hidrojen çekirdeklerinin tüm manyetik momentlerinin toplam etkisiyle net bir manyetizasyon vektörü oluşur. Hidrojen çekirdeklerine Larmor frekansında bir radyo sinyali uygulanarak net manyetizasyon vektörü belirli bir açıyla döner ve uzunlamasına (longitudinal-z) ve enine (transverse-x,y) mıknatıslanma olmak üzere iki mıknatıslanma vektör bileşenini oluşturur. Enine mıknatıslanmanın bir alıcı bobin (radyo frekans) tarafından algılanmasıyla (akım indüklemesi) MR sinyali elde edilir. Oluşan MR sinyallerinin bilgisayar ortamında yeniden yapılandırılmasıyla (Fourier dönüşümü vb tekniklerle) doku ortamının kesitsel MR görüntüleri oluşturulur (Chrysikopoulos 2009). MRG sistemi Şekil 3.8’de gösterildiği gibi, manyetik sargılar, gradiyent sargılar, radyo frekans sinyal verici ve alıcı, görüntülerin yeniden yapılandırması ve kontrol işlemleri için bir bilgisayardan oluşmaktadır (Sprawls 2000).



Şekil 3.8. MRG sisteminin temel parçaları (Sprawls 2000)

3.2.2.2. MRG'de sekans ve düzlemler


Klinik MRG’de Hidrojen atomu, vücuttaki bolluğu ve çekirdeğinde bir protona sahip olması (net dönüş) nedeni ile tercih edilen MR-aktif çekirdeklerdendir (Bitar vd. 2006). Hidrojen atomu içeren dokunun manyetik alana yerleştirilmesiyle hidrojen çekirdeklerinin oluşturduğu manyetizasyon vektörüne farklı RF darbelerinin belli zamanlarda uygulanması temelinde manyetik rezonans sekansları oluşturulur (Mohindra ve Neyaz 2015). Uyarılan Hidrojen çekirdeklerinin oluşturduğu bu manyetizasyon vektörü, RF darbelerine maruz kalarak uzunlama düzlemden (longitudinal-z) taban durum olarak adlandırılan enine düzleme (transverse-x,y) geçiş gösterir ve bu esnada RF sinyalleri salınır.

RF enerjisinin belli bir süre sonra kesilmesiyle enine düzlemdeki manyetizasyon vektörü, çekirdeklerin aşamalı olarak faz dışında dönmeye başlamasıyla zamanla azalır (Bitar vd. 2006). Her özel dokuda enine düzlemdeki gevşeme veya azalma sürelerindeki farklılığı belirtmek ve görüntü bilgisi üzerindeki etkilerini ifade etmek üzere tanımlanmış bazı kavramlar vardır. *T2 değeri* (spin-spin), manyetizasyon vektörünün enine gevşeme süresi olarak bilinir. Manyetizasyon vektörünün enine düzlemde tekrar uzunlama düzleminde artış göstererek eski haline gelme süresine *T1 değeri* (spin-lattice) denir. T1 değeri her bir özel dokuya özgüdür (Sprawls 2000). MR görüntülerinde belirli bir kontrast türünü oluşturmak için *TR* (tekrarlama süresi) ve *TE* (eko-yankı süresi) olmak üzere iki önemli parametreden yararlanılır (Bitar vd. 2006; Mohindra ve Neyaz 2015). TR, iki RF darbesi arasındaki uygulanma süresi iken, TE çekirdeklere uygulanan bir RF darbesinden sonra oluşan sinyalin tepe noktaları (zirve) arasındaki süresidir (Bitar vd. 2006; Kumar 2013). TR, T1 ağırlıklı görüntülerde kontrastı etkilerken; T2 ağırlıklı görüntülerde kontrastı TE parametresi etkiler (Bitar vd. 2006).


Anatomik görüntüler üzerindeki tümörlü bölgelerin tanısında ve değerlendirmesinde farklı MRG sekans görüntülerinden faydalanılır. Klinikte yaygın kullanılan sekans görüntülerinden bazıları T1-ağırlıklı (T1-weighted; T1w) MRG, kontrast arttırmalı T1-ağırlıklı MRG (T1-weighted MRI with contrast enhancement; T1wc), paramanyetik ajan (gadolinium (Gd) şelatı) uygulanmasıyla T1w1, T2-ağırlıklı (T2-weighted; T2w) görüntü, proton yoğunluk ağırlıklı (Proton density-weighted; PDw) MRG, Sıvı zayıflatmalı tersine geri kazanım (Fluid Attenuated Inversion Recovery; FLAIR), vb. bulunur (Liu vd. 2014).

- **T1 ağırlıklı MRG:** Bu sekans, dokuların T1 gevşeme sürelerindeki farklılıkları esas alır. T1 ağırlıklı görüntülerde Şekil 3.9a'da görüldüğü gibi yağ dokusu daha parlak görünürken, su daha karanlık bir görünüm sergiler. Paramanyetik kontrast ajanları (gadolinium bileşikleri gibi) için T1 ağırlıklı sekanslar en iyi kontrastı oluşturan sekanslardır (Anonymous 8). T1 ağırlıklı arttırılmış kontrastla tümör sınırlarına biriken kontrast ajanları sayesinde daha net (daha parlak) ve anatomik ayrıntılar daha detaylı görülür (Patra vd. 2019). Bu yönüyle T1 ağırlıklı MRG sekansı beyin tümör yapı analizlerinde yaygın şekilde kullanılır (Liu vd. 2014).
- **T2 ağırlıklı MRG:** Bu sekans, dokuların T2 gevşeme sürelerindeki farklılıklara dayanır. Dokulardaki hidrojen atomlarının enine düzlemdeki hizalı dönüşleri zamanla kaybolur ve bu bozulmalar T2 ağırlıklandırmasında ifade edilir. T2 ağırlıklandırma sekansı uzun TR ve TE süre eğilimi gösterir. T2 ağırlıklı sekanslı görüntülerde Şekil 3.9b'de görüldüğü gibi yağ dokusu orta parlak görülürken, sıvılar (su) parlak (beyaz) görünür (Anonymous 9). T2 ağırlıklı görüntüleme ile tümörler, ödem, iskemi (ischemia) gibi patolojik durumlar daha parlak şekilde değerlendirilir (Patra vd. 2019).
- **Proton yoğunluk ağırlıklı MRG:** Uzun TR süresi ve kısa TE süreleri kullanılarak oluşturulan görüntülerdir. Beyin görüntülerinde Şekil 3.9c'de görüldüğü gibi beyaz maddeyi koyu gri olarak, gri maddeyi ise parlak göstererek beyaz ve gri madde arasındaki kontrast ortaya çıkar. Fakat bu sekansta beyin ve beyin omurilik sıvısı arasındaki kontrast düşüktür. Bu görüntü sekansı eklem rahatsızlıklarının tespitinde faydalıdır (Anonymous 10).

- **FLAIR (Fluid Attenuation Inversion Recovery (Sıvı zayıflatmalı tersine geri kazanım):** Belirli dokulardan (yağ veya sıvı gibi) gelen bazı sinyallerin seçici olarak alınmasını önlemek için kullanılan tersine çevirilmiş sekanslardan birisidir. Bu sekans uzun çevirme süresine sahiptir ve su moleküllerinin sinyallerini baskılar (Liu vd. 2014); (Anonim 11). FLAIR sekanslı MR görüntülerinde Şekil 3.10c’de görüldüğü gibi beyin omurilik sıvısı karanlık görünür (Anonim 11). Böylece bu sekans ödem bölgeleriyle beyin omurilik sıvısının ayırt edilmesine yardımcı olur (Liu vd. 2014).




Şekil 3.9. Farklı MR sekanslarındaki beyin kesit görüntüleri: **a)** T1 ağırlıklı; **b)** T2 ağırlıklı; **c)** PD ağırlıklı (Öziç 2013)



Şekil 3.10. MR görüntü sekansları kullanımı ile gliom (glioblastoma) tümörünün görünümü: **a)** Kontrast madde sonrası (gadolinium ile geliştirilmiş) T1 ağırlıklı görüntü; **b)** T2 ağırlıklı görüntü; **c)** FLAIR görüntü (Nilsson vd. 2018)

MRG’de sağıtal, koronal ve aksiyel olmak üç farklı düzlem kullanılarak beyin farklı kesit görüntüleri oluşturulabilmektedir. Sağıtal düzlem ile beyin soldan sağa doğru olacak şekilde kesit görüntüleri oluşturulur. Koronal düzlem ile beyin arkadan öne doğru kesit görüntüleri elde edilir. Son olarak aksiyel düzlem ile beyin yukarıdan aşağıya doğru olacak şekilde kesit görüntüleri oluşturulur (Cuşkun 2019).



Şekil 3.11. Beyin MR görüntülerinin farklı düzlemdeki kesitleri; **a)** aksiyel düzlemdeki beyin görüntüsü; **b)** sagittal düzlemdeki beyin MR görüntüsü; **c)** koronal düzlemdeki beyin MR görüntüsü (Cuşkun 2019)

3.2.2.3. Beyin tümörlerinin MR görüntülerinde lokalizasyonu ve özellikleri


MR, iyonize edici radyasyon kullanmadan, iyi yumuşak doku kontrastı sağlayarak tanı koyuculara beyin tümörlerinin şekli, boyutu ve lokalizasyonu ile ilgili önemli bilgiler sunan bir görüntüleme tekniğidir (Liu vd. 2014). Beyin tümörlerinden meninjiyomlar genellikle beyni ve omuriliği çevreleyen zar yapılarında (meninks) oluşum gösteren ve yavaş büyüyen tümörlerdir. Gliom tümörleri ise beyin ve omurilikteki glial hücrelerde oluşum göstermektedir. Hipofiz tümörleri de hipofiz bezinde oluşum gösterirler. Gliom ve meninjiyomların MR görüntülerinde hipofiz tümörleri gibi tek bir bölgede bulunan sabit bir lokalizasyonu bulunmamaktadır (Larjavaara vd. 2007).

3.3. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme

Gelişen ve gelişmeye devam eden teknolojinin varlığı, internetin herkes tarafından kolaylıkla ulaşılabilir olması sayesinde veri hacmi ve çeşitliliği artmaya devam etmektedir. International Data Corporation (IDC)'nin Veri Çağı 2025 raporuna göre, 2018'de 33 Zettabayt olan küresel veri dünyasının 2025'e kadar 175 Zettabayt'a çıkacağını öngörülmektedir. Aynı raporda 2025'te, dünyada depolanmış verilerin % 49'unun genel bulut ortamlarında tutulacağından bahsedilmiştir (Rydning 2018). Bulut ortamlarında, internette veya bilgisayarlarda depolanan tüm bu veriler güçlü donanımlarla işlenip, anlamlandırılır hale gelmiştir. Çok sayıda veriye ulaşılabilirliğin kolaylaşması, donanımların gelişmesi yapay zekâ (YZ) sistemlerinin gelişimini de beraberinde getirmiştir. Aynı zamanda gelişmekte olan YZ sistemlerinin hata oranı insana göre daha kabul edilebilir seviyelerde olmaya başlamıştır (Kavuncu 2018).

YZ sistemleri insanların öğrenme, muhakeme yapma, karar verme gibi zihinsel faaliyetlerini temel alarak oluşturulmuş sistemlerdir (Kavuncu 2018). YZ terimi bir makine veya bilgisayar programının insan beyni gibi düşünme (akıl), anlama ve öğrenme yeteneğini ifade etmektedir (Öztürk ve Şahin 2018). YZ tekniklerinden bir tanesi olan makine öğrenmesi yöntemleri ezberden ziyade, insanlar gibi deneyimler sayesinde otomatik olarak gelişen ve öğrenen sistemlerdir Derin öğrenme yöntemi ise Şekil 3.12'de gösterildiği gibi makine öğreniminin bir alt kümesidir. Derin öğrenmenin, makine öğrenmesiyle farklılık gösteren en önemli yönü verilerin analizinde uzman faktörünü

kullanmadan veri öz niteliklerini yapısındaki çok katmanlı sinir ağıyla öğrenebilmesidir (Kayaalp ve Süzen 2018; Yan vd. 2015).



Şekil 3.12. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki

1980’li yıllarda ortaya çıkan derin öğrenme kavramı, donanım ve büyük miktarda etiketlenmiş veri yetersizliği nedeniyle ilerleme kaydedememiştir. Günümüzde ise derin öğrenme gelişmeye devam ederek, YZ’nin en önemli ve daha çok kullanılan bir alt dalı olmuştur (Kızrak ve Bolat 2018). Derin öğrenme yöntemleri kullanılarak karmaşık verilerin hızlı bir şekilde öğrenilmesi ve uygulanması sağlanmıştır (Kayaalp ve Süzen 2018).

3.3.1. Makine öğrenmesi


Makine öğrenmesi, verilerin bilgisayar sistemleriyle otomatik analizlerinin yapılabilmesi, verilerden öğrenebilen, deneyimlerle sistem iyileşmesi göstererek hızlı çıkarımlarda bulunabilen YZ’nin bir alanıdır. Makine öğrenmesi algoritmaları, statik programlama algoritmalarından farklı olarak insan talimatına veya kurallara ihtiyaç duymadan verilerden öğrenebilecek ve benzer problemlerin çözümleri için öğrenilen bilgileri kullanarak tahminler yapabilecek şekilde yapılandırılmışlardır (Choudhary ve Gianey 2017). Makine öğrenmesi algoritmaları, metin ve belge sınıflandırması, konuşma tanıma, bilgisayar görüşü, sürücüsüz araç, tıbbi teşhis, tavsiye sistemleri gibi fiyat tahmini gibi birçok farklı alanda problemin türüne ve sonucuna göre sınıflandırma ve regresyon için kullanılabilir (Choudhary ve Gianey 2017). Makine öğrenme algoritmaları genellikle gözetimli, gözetimsiz ve takviyeli öğrenme olarak kategorize edilmektedir (Çürükoğlu 2019).

Gözetimli makine öğrenme algoritmaları, girdi veri seti ve etiketli çıktı verileri üzerinden eğitilirler. Algoritmaların test aşamasında ise çıktı bilgisi bilinmeyen verilerin algoritmanın eğitimle deneyimlediği girdi veri ve etiketli çıktı arasındaki ilişkilendirme bilgisine göre Şekil 3.13A’da gösterildiği gibi sınıflandırma veya regresyon yöntemleri ile hedef çıktı tahmininde bulunması beklenir. Oluşturulan model sayesinde etiket bilgisi olmayan verilerin de algoritmanın öğrendiği ilişkilendirme becerisine göre sonuç tahmini yapılabilir. Gözetimli makine öğrenmesinde k-En Yakın Komşuluk (k-Nearest Neighbors; KNN), Yapay Sinir Ağları (Artificial Neural Network; ANN), Destek Vektör

Makinaları (Support Vector Machine; SVM), Karar Ağaçları (Decision Trees; DTs), Doğrusal Regresyon (Linear Regression), Lojistik Regresyon (Logistic Regression) çoğunlukla kullanılan algoritmalar (Çürükoğlu 2019). Genel olarak gözetimli öğrenme algoritması, kolay kullanılması ve doğruluğunun daha kolay hesaplanabilmesi sebebiyle diğer algoritmalarla oranla daha çok kullanılmaktadır (Ayturan 2019).

Gözetimsiz makine öğrenmesinde ilgili algoritmalar Şekil 3.13B’de gösterildiği gibi veri kümelerinin sonuç (etiket) bilgisi olmadan eğitilir ve algoritma giriş veri özellik bilgilerini kümeleyerek hedef sonuç tahmininde bulunur. Gözetimsiz makine öğrenmesinde Kümeleme (Clustering), Birlikte Kuralları (Association Rules), Temel Bileşen Analizi (Principal Component Analysis; PCA) çoğunlukla kullanılan algoritmalar (Metlek ve Kayaalp 2020).

Takviyeli öğrenme, ödül ve cezalardan oluşan bir veri setinin dinamik bir çevrede geri bildirimlerle yapay zekâ ajanının görev öğrenme performansının artırıldığı dinamik programlamadır. Bir takviyeli öğrenme algoritması, çevresiyle etkileşime girerek öğrenmektedir. Temsilci (Ajan), Şekil 3.13 C’de gösterildiği gibi doğru performans gösterdiğinde ödüllendirilir, yanlış performans gösterdiğinde ise ceza alır. Temsilci, ödülünü en üst düzeye çıkarıp cezasını en aza indirerek bir insandan müdahale olmaksızın öğrenme işlemini gerçekleştirmeye çalışır (Zhang 2020).



Şekil 3.13. Makine öğrenmesi algoritmaları: **A)** Gözetimli öğrenme algoritması; **B)** Gözetimsiz öğrenme algoritması; **C)** Takviyeli öğrenme algoritması (Auger vd. 2021)


3.3.1.1. Yapay sinir ağları

Yapay sinir ağları, insan beynindeki sinir hücrelerinin (nöron) oluşturduğu ağ yapısı düşünülerek oluşturulmuş makine öğrenmesi metodudur. Yapay sinir ağı algoritması ile bilgisayar sistemlerinin de insan sinir sistemindeki gibi bilginin öğrenilme, analiz ve çıkarım süreçlerinin hızlı ve doğru olarak yapılabilmesi hedeflenir.

YSA, insan sinir sistemindeki nöronların bilgilerini, sinaptik bağlantılarla (sinapslarla) Şekil 3.14b’de gösterildiği gibi komşu nöronlara aktarma işlemlerinin bir benzetimini kullanır. Biyolojik bir sinir hücresi genel olarak Şekil 3.1a’da gösterildiği

gibi dendrit, hücre gövdesi (soma) ve akson (gövde) olmak üzere temel üç bölümden meydana gelmiştir. Dendritler, sinir hücresinin gövdesine bağlıdır ve nöronlardan gelen sinyalleri dallanmış yapılarıyla almaktadır. Aksonlar nöronların komşu nöronlara sinyalleri gönderdiği sinyal iletici kısımdır.

Sinir hücreleri arasındaki sinyal iletimi bir nöronun akson ucuyla komşu nöronun dendritleri arasındaki sinapslarla sağlanmaktadır. Komşu nörondan gelen elektrokimyasal sinyaller sinaptik boşluktan (nöronlar arası boşluk) bilginin aktarılacağı nöronun dallı yapı gösteren dendritleri aracılığıyla alınır ve sinir hücresinin hücre gövdesinde bulunan çekirdeği tarafından toplanır. Çekirdekte toplanan elektrokimyasal sinyaller belli bir elektriksel potansiyel eşiği (sinaps eşiği) aştığı zaman hücre gövdesinden aksona iletilirler. Bu sayede akson aracılığıyla sinyallerin komşu nöronlara iletimi gerçekleşir (Zou vd. 2008).




Şekil 3.14. Biyolojik nöronlar ve yapay nöronlar arasındaki benzerlik: **a)** biyolojik sinir hücre yapısı ve sinir hücrelerinin sinaptik bağlantısı; **b)** yapay nöronun yapısı (Lee vd. 2017)

YSA, biyolojik sinir ağlarının yapı ve işlevleri düşünülerek oluşturulmuş matematiksel bir modeldir. YSA'nın temel yapı taşı olan yapay nöronun tasarımı ve işlevselliği Şekil 3.15'te görüldüğü gibi biyolojik bir nöronun gözlenmesiyle oluşturulmuştur (Krenker vd. 2011). Biyolojik nörona ilgili bilgiler dendritler aracılığıyla nörona gelir ve somada işlenerek akson üzerinden diğer nöronların dendritlerine iletilirler (Şekil 3.14a). Yapay nörona bilgi, bir yapay nöronun gövdesine ağırlıklı girdiler (model girişindeki her girdi bireysel ağırlıkları ile çarpılır) ile gelir. Yapay bir nöronun gövdesi ağırlıklı girişleri ve yanlılık (bias; b) değerini bir toplama fonksiyonuyla toplar ve sonucu transfer fonksiyon olarak adlandırılan bir aktivasyon fonksiyondan geçirerek bilgiyi işler. Sonunda yapay bir nöron işlenmiş bilgiler çıktı yoluyla diğer yapay nöronlara iletilir (Şekil 3.14b). Yapay bir nöronun modelinin matematiksel ifadesi (3.1)'de verilmiştir:

$$y(k) = F\left(\sum_{i=0}^m w_i(k) \cdot x_i(k) + b\right) \quad (3.1)$$

Denklem 3.1’de görülen $x_i(k)$ ifadesi 0’den m ’ye kadar değer alan i ifadesinin ayrık zaman k ’da ifade edilen giriş değerlerini temsil ederken $w_i(k)$ ağırlık değerlerini temsil eder. Denklem 3.1’de b bias değeri, F transfer fonksiyon son olarak $y(k)$ ayrık zaman k için çıkış değerini gösterir. Transfer fonksiyonu, yapay nöronun çözmesi gereken probleme göre seçilir. Transfer fonksiyonlarına örnek olarak Adım fonksiyonu (Step function), Doğrusal fonksiyon (Linear function) ve Doğrusal olmayan fonksiyon (Non-linear (Sigmoid) function) verilebilir (Krenker vd. 2011).




Şekil 3.15. Biyolojik ve yapay nöronun tasarımı: **a)** Biyolojik nöronun bölümlerinin (soma, dendrit ve akson) temsili gösterilmiştir; **b)** Yapay nöronun girişleri, ağırlıkları, toplama fonksiyonu, transfer fonksiyonu, bias değeri ve çıkış temsili gösterimi (Krenker vd. 2011).

Yapay nöronların birbirlerine bağlanmasıyla, yapay sinir ağları oluşturulmuş ve bu sayede yapay nöronların tam potansiyeli ve hesaplama gücü daha iyi şekilde kullanılarak doğrusal olmayan problemlerin çözümünde kullanılır hale gelmiştir (Krenker vd. 2011). Rosenblatt tarafından geliştirilen yapay sinir ağlarının en eski ve ileri beslemeli ağı perseptron olup yalnızca bir tek gizli katmana (hidden-layer) sahiptir ve yalnızca doğrusal olarak ayrılabilir problemleri çözebilmektedir. Tek katmanlı perseptron, XOR gibi doğrusal olarak ayrılamayan problemlerin çözümünde yetersiz kalmıştır. Çok katmanlı perseptron (multiple-layer perceptron; MLP) doğrusal olmayan problemlerin çözümünde en çok kullanılan sinir ağıdır (Zou vd. 2008).

Geriye yayılım algoritması genellikle çok katmanlı perseptron eğitimlerinde kullanılan algoritmadır. Algoritmada, girdiler ağ üzerinden yayılır ve bir çıktı değeri hesaplanır. Hesaplanan çıktı ile doğru çıktı değeri arasındaki maliyet fonksiyonu olarak adlandırılan hata, ağın başlangıç ağırlıklarını düzenlemek üzere çıktıdan girişe geri döndürülür. Algoritma, ağın maliyet fonksiyonunu Gradyan İniş (Gradient Descent; GD) optimizasyon algoritmasıyla en aza indirilmeye çalışır. Ağın çıktısı ve doğru çıktı arasındaki hata değerinin azalması, optimum ağırlık değerleri elde edilene kadar yapay sinir ağında bu süreçler tekrarlanır (Zou vd. 2008). Çok katmanlı perceptronun öğrenim hızı ve performansı, yapay sinir ağındaki gizli katman sayısından büyük ölçüde etkilenir ve


Şekil 3.16’da gösterildiği gibi gizli katman sayısının artması, ağın örüntü tanıma kabiliyetini iyileştirerek artırır (Matarollo vd. 2013).



Şekil 3.16. Çok katmanlı perseptronun örüntü tanıma kabiliyeti üzerindeki katman sayısının etkisi (Matarollo vd. 2013)

3.3.2. Derin öğrenme

Derin öğrenme, çok sayıda (2 veya daha fazla) gizli katmana sahip bir YSA türü ve makine öğrenmesinin bir çalışma alanıdır. YSA mimarilerindeki katman sayılarının artırılmasıyla doğrusal olmayan bilginin anlamlandırılma ve çıkarımında iyileşme görülmüştür (Lee vd. 2017). Derin öğrenme mimarilerinin Şekil 3.17’de gösterildiği gibi temel YSA mimarilerinden tek farkı daha fazla nöron ve katman içermesidir (Ravi vd. 2016). Derin öğrenme mimarilerinin en önemli özellikleri verilerdeki öz nitelikleri bir uzmana ihtiyaç olmaksızın eğitimlerle kendi kendilerine öğrenebilmeleri ve ilgili probleme göre öz nitelik çıkarımında bulunabilmeleridir (Aksoy vd. 2020).




Şekil 3.17. YSA mimari yapıları, **a)** Giriş ve çıkış katmanları arasında 3 gizli katman bulunan derin öğrenme sinir ağı; **b)** Giriş ve çıkış katmanları arasında 1 gizli katman bulunan temel yapay sinir ağı (Lee vd. 2017)

YSA mimarileri 1950’lilerde tanıtılmasına rağmen derin katmanlı YSA mimarileri belli bir süre, yeterli verinin olmaması, bilgisayar sistemlerindeki bilgi işlem gücünün yetersizliği, gradyan kaybolması (vanishing gradient), aşırı uyum (overfitting problems) gibi sınırlamalardan dolayı kullanılamamıştır. Günümüzde ise çok sayıda veriye ulaşılabilirliğin kolaylaşması, grafik işlem birimleriyle (Graphics Processing Unit; GPU) gelişmiş bilgi işlem gücü ve donanımdaki gelişmeler derin öğrenmenin yapay zekâ alanında kullanılmasını sağlamıştır (Lee vd. 2017; Ravi vd. 2016).

Derin öğrenme mimarileri YSA mimarilerinde olduğu gibi gözetimli ve gözetimsiz olarak eğitilebilmektedir. Gözetimli öğrenmede, etiketlenmiş veriler kullanılarak sınıflandırma veya regresyon problemlerinin hedef değer tahmininde hatayı en aza indiren ağırlık değerlerinin öğrenilmesi gerçekleşir. Gözetimsiz öğrenmede etiketli veriler kullanılmamaktadır. Gözetimsiz öğrenme genellikle kümeleme, özellik çıkarımı ve boyutluluk azaltma (dimensionality reduction) için kullanılır (Ravi vd. 2016).

3.4. Evrişimli Sinir Ağları ve Katmanları

Evrişimli Sinir Ağı (ESA) biyolojik görsel korteksindeki sinirsel bağlantıdan ilham alınarak tasarlanmış çok katmanlı derin öğrenme mimarisidir. ESA mimarisi, görüntü sınıflandırma, görüntü ve video tanıma, konuşma tanıma, doğal dil işleme, tavsiye sistemleri, medikal görüntü analizi gibi alanlarda başarılı performans göstermiştir. ESA mimarileri görseller ile ilgili görevlerde (bilgisayarla görü alanı) geleneksel yöntemlerden daha başarılıdır (Hosseini vd. 2020; Wani vd. 2020). Temelinde evrişim işlemi (konvolüsyon) olarak adlandırılan matrisler arasındaki doğrusal matematiksel işlemlerde verideki üst düzey özelliklerin öğrenimi yatar. Esas olarak Şekil 3.18’de gösterildiği gibi evrişimli katman, doğrusal olmayan katman (aktivasyon fonksiyon katmanı), havuzlama katmanı ve tam bağlantılı katmanları içerir (Albawi vd. 2017).




Şekil 3.18. ESA temel yapısı (Fırıldak ve Talu 2019)

3.4.2. Evrişim (Konvolüsyon) katmanı

ESA mimarisindeki bir evrişim katmanı doğrusal ve doğrusal olmayan (evrişim işlemi ve aktivasyon işlemi) işlem kombinasyonunu kullanarak özellik çıkarımı yapmaktadır (Yamashita vd. 2018). Evrişim katmanı ile özellik haritaları olarak adlandırılan yeni görüntüler üretilir. Özellik haritası, orijinal görüntünün kendine has özelliklerini vurgular. Evrişim katmanı sinir ağı katmanlarının kullandığı bağlantı ağırlıkları ve ağırlık toplam yerine görüntülerin özellik haritasını oluşturan evrişim

filtreleri kullanır. Evrişim katmanı, kullanılan evrişim filtre sayısı ile aynı sayıda görüntü özellik haritası oluşturur. Örnek verilirse Şekil 3.19’da gösterildiği gibi dört farklı 5*5’ boyutunda evrişim filtresi kullanılmış ve bir resimden dört farklı özellik haritası elde edilmiştir. Evrişim katmanlarındaki filtre boyutları iki boyutlu matrisler olmak üzere genellikle 5*5 veya 3*3 matris boyutlarında olurken son uygulamalarda 1*1 matris boyutu da kullanılmıştır. Evrişim filtrelerinin matris değerleri ağırlık eğitimi sürecinde belirlenir ve eğitim süreci boyunca değerler uygun değerlere güncellenir.



Şekil 3.19. Evrişim katmanında yapılan işlemler. (Kare gri tonlamalı 5*5 boyutunda evrişim filtreleri, daire içine alınmış * işareti evrişim işlemi ve ϕ işareti aktivasyon fonksiyonunu gösterir.) (Kim 2017)

Evrişim işleminde gerekli olan iki önemli parametre görüntünün matris değerleri ve görüntünün özellik haritası için gerekli olan evrişim filtreleridir. Evrişim filtreleri özellik haritası oluşturabilme için görüntü üzerinde belli adımlarda kaydırılır. Görüntünün matris değerleri ile filtrenin matris değerlerinin örtüşen noktalar çarpılır ve tüm çarpım değerleri toplanır. Toplam sonucu yeni oluşturulan özellik haritasının matris değeri olarak belirlenir. Özellik haritasının matris değerleri filtrenin görüntü üzerinde kaydırılma işlemlerinin sonlanmasıyla tamamlanır. Devamında elde edilen özellik haritası doğrusal olmayan bir aktivasyon fonksiyonuyla (ReLU, sigmoid ve tanh fonksiyonları) işlenir ve evrişim katman çıkışı oluşturulur (Kim 2017).

9	3	2	4	5	2	7	8	1
8	2	6	1	2	4	4	5	3
8	7	1	3	1	0	2	8	9
3	1	5	2	7	2	8	7	2
1	3	9	8	5	1	5	8	3
4	7	2	1	0	3	4	1	3
3	1	2	0	4	2	1	2	7
4	0	1	3	8	8	9	7	2
2	9	5	1	6	2	3	2	7

9×9

*

1	0	-1
1	0	-1
1	0	-1

3×3
filtre

=

-16	-4	-1	-2	5	15	0
-7	-4	-2	0	4	14	0
3	2	-2	-10	2	20	-1
8	0	-4	-5	5	10	-9
5	-2	-4	-3	1	5	3
-6	-4	7	9	2	-3	-2
-1	-6	10	8	-5	-1	3

7×7


Şekil 3.20. Örnek evrişim işlemi (Cuşkun 2019)

Şekil 3.20’de 3*3 boyutlu bir evrişim filtresiyle 9*9 matris boyutunda bir resim matrisinin evrişim işlemi görülmektedir. Resim matrisi üzerindeki her bir renkli kare evrişim filtresinin resim üzerinde sol üst köşeden başlayarak sağa doğru kaydırılmasını ve filtreyle (x ve y eksenlerine göre simetriği alınan) resim matrisi üzerinde örtüşen değerlerin çarpılıp toplanmasını göstermektedir. Denklem 3.2’de resim matrisi üzerindeki kırmızı kutuyla gösterilen bölgenin evrişim işlemi gösterilmektedir. Evrişim filtresi bulunan değerler yeni oluşturan 7*7 boyutundaki özellik matrisinde yeni değer olarak eklenir.

$$(4 \times (-1)) + (5 \times 0) + (2 \times 1) + (1 \times (-1)) + (2 \times 0) + (4 \times 1) + (3 \times (-1)) + (1 \times 0) + (0 \times 1) = -2 \quad (3.2)$$

3.4.3. Aktivasyon fonksiyonları

Evrişim katmanında yapılan işlemlerden biri evrişim işlemi iken diğeri aktivasyon fonksiyonunun kullanımıdır. Evrişim işlemi doğrusal bir işlemdir ve bu nedenle çıktılarına doğrusalsızlık özelliği kazandırılmak için çıktılar doğrusal olmayan bir aktivasyon fonksiyonundan geçirilir. Aktivasyon fonksiyonu olarak önceleri Şekil 3.21a’da grafiği gösterilen sigmoid veya Şekil 3.21b’de grafiği gösterilen hiperbolik tanjant gibi düzgün doğrusal olmayan fonksiyonlar kullanılırken günümüzde yaygın olarak Şekil 3.21c’de grafiği gösterilen doğrusal olmayan ReLu fonksiyonu kullanılır (Yamashita vd. 2018).



Şekil 3.21. ESA’nda yaygın kullanılan aktivasyon fonksiyonları: **a)** sigmoid; **b)** hiperbolik tanjant (tanh); **c)** düzeltilmiş doğrusal birim (rectified linear unit (ReLU)) (Yamashita vd. 2018)

- **Sigmoid aktivasyon Fonksiyon:** Sigmoid aktivasyon fonksiyonunun matematiksel ifadesi Denklem 3.3’te verilmiştir. Bu fonksiyon Şekil 3.21a’da gösterildiği gibi "S" şekline benzer bir grafiğdir ve girdi değerlerini $[0, 1]$ aralığına çekmektedir (Wani vd. 2020).

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.3)$$

- **Tanh aktivasyon Fonksiyon:** Hiperbolik tanjant aktivasyon fonksiyonu sigmoid aktivasyon fonksiyonuna benzer grafik gösterir fakat Şekil 3.21(b)’de gösterildiği gibi girdi değerlerini $[-1, 1]$ aralığına çeker. Tanh aktivasyon fonksiyonunda negatif

değerli girişler negatif değerlere eşleştirilirken sıfır değerli girişler sıfıra yakın şekilde eşleştirilir (Wani vd. 2020).

- **ReLU aktivasyon fonksiyon:** ReLU aktivasyon fonksiyonunun matematiksel ifadesi Denklem 3.4'teki gibidir. ReLU aktivasyon fonksiyonunun matematiksel ifadesine göre, giriş değerinin 0'dan küçük olduğu durumda çıktıyı 0'a eşitlerken diğer tüm durumlarda ise çıktıyı giriş değerinin aynısı olarak belirler. ReLU aktivasyon fonksiyonu Şekil 3.218c(c)'de gösterildiği gibi $x < 0$ olduğunda çıkış 0 iken $x > 0$ olduğunda eğimi 1 olan doğrusal bir grafik özelliği gösterir (Wani vd. 2020).


$$f(x) = \max(0, x) \quad (3.4)$$

- **Softmax aktivasyon fonksiyon:** Çoklu sınıf sınıflandırma problemleri için genellikle bir sinir ağının çıktı katmanında kullanılan aktivasyon fonksiyonudur. Bir sinir ağının çıktı katmanındaki nöron sayısı hedeflenen sınıf sayısına eşit şekilde oluşturulur. Softax aktivasyon fonksiyonu oluşturulan bu nöronların çıktı değerlerini Denklem 3.5'teki matematik ifadesi ile bir olasılık değerine eşitler (Wani vd. 2020).

$$\sigma(x_j) = \frac{e^{x_j}}{\sum_{k=1}^n e^{x_k}} \quad j = 1, \dots, n \text{ için} \quad (3.5)$$

3.4.4. Havuzlama katmanı

ESA mimarilerinde evrişim ve aktivasyon katmanlarından sonra isteğe bağlı olarak havuzlama katmanı (pooling layer) kullanılmaktadır. Bu katman, giriş görüntüsündeki belli bir alanın piksellerinin ortalamasını veya maksimum değerini alarak görüntünün boyutunu küçültür. Örnek olarak verilen Şekil 3.22'deki 4*4 matris boyutundaki giriş görüntüsü havuzlama işlemi için 2*2 boyutunda dört giriş bölgesine ayrılmıştır. Maksimum havuzlama işleminde (2*2 boyutlarındaki bir filtre ve adım 2 ile) Şekil 3.19'da gösterildiği gibi her bir giriş bölge piksel değerinin en büyüğü alınırken, ortalama havuzlamada her bir giriş bölge piksel değerlerinin ortalaması alınır. Böylece Şekil 3.19'da gösterildiği gibi 2*2'lik her bir giriş alanının 1 bloğa (piksel) eşlenmesiyle 4*4 boyutundaki giriş görüntüsü 2*2 boyutuna düşürülür. Havuzlama katmanı ile girdinin boyutu küçültülerek, ağın hesaplanması gereken parametre sayısı azaltılarak, hesaplama yükü azaltılır ayrıca havuzlama işlemi ağın aşırı ezberleme durumlarını önlemekte faydalıdır (Kim 2017; Wani vd. 2020).



Şekil 3.22. Maksimum havuzlama ve ortalama havuzlama işlem örnekleri (Kim 2017)

3.4.5. Tam bağlı katman (Fully connected layer-Dense)


Evrişimli sinir ağları sınıflandırma ve özellik çıkarma olmak üzere iki temel üzerinde yapılandırılmıştır. Evrişim ve havuzlama katmanları özellik çıkarma aşamasında etkinken, bir veya daha fazla tamamen bağlı katman ile softmax aktivasyon fonksiyon katmanı sınıflandırma işleminde etkindir (Wani vd. 2020). ESA mimarisindeki tam bağlı katman yapısı geleneksel bir sinir ağındaki nöronların birbiriyle olan bağlantı yapısı gibidir. Tamamen bağlantılı bir katmandaki her nöron (düğüm) bir sonraki ve bir önceki katmandaki her nörona doğrudan öğrenilebilir bir ağırlık değeriyle bağlıdır (Albawi vd. 2017).

ESA sinir ağında evrişim veya havuzlama katmanları sonucunda görüntü verisinden iki boyutlu matrisler halinde elde edilen özellik haritaları, tamamen bağlı katmanın (yoğun katman) ilk katmanındaki her nörona düzleştirme katmanı aracılığıyla tek boyutlu bir sayı dizisine (veya vektör) dönüştürülerek bağlanır (Yamashita vd. 2018). ESA mimarisindeki eğitim aşaması diğer sinir ağ mimarilerindeki gibidir. ESA, yapısındaki ağırlıkları ve evrişim işleminde kullanılan filtrelerdeki değerlerin güncellenmesi için bir optimizasyon algoritması kullanır. Optimizasyon algoritması sınıflandırma hatasını (kayıp değer) alır ve filtrelerin ve ağırlıkların güncellenmesi için hatayı (türevi alınarak) tekrar ağıya yayar (Ismael vd. 2020). Tamamen bağlı bir sinir ağının çıktı katmanındaki nöron sayısı sınıflandırma görevindeki sınıf sayısı ile eşit olarak belirlenir (Yamashita vd. 2018). Genellikle çıktı katmanında çoklu sınıflandırma problemlerinin çözümünde softmax aktivasyon fonksiyonu kullanılır. Softmax sınıflandırıcısı, gerçek değerleri normalleştirmekte (değerleri 0 ve 1 arasına çeker) ve toplam olasılıkları 1 olacak şekilde her sınıf için olasılık değeri üretmektedir (Wani vd. 2020; Yamashita vd. 2018).

3.4.6. Seyreltme katmanı (Dropout)

ESA mimarisindeki sınıflandırma kararının verildiği tam bağlı katmanlar tüm özellik haritalarıyla bağlantılı olduğu için temel veri setine karşı aşırı uyum gösterebilmektedirler. Aşırı uyum (overfitting) sonucunda model, eğitim veri seti üzerinde yüksek başarı gösterirken yeni veri seti üzerine düşük başarı gösterir. Aşırı uyum sorununun çözümü için modelin eğitimi sırasında Şekil 3.23b'de gösterildiği gibi rasgele

olarak bazı nöronların bağlantılarıyla beraber etkisiz bırakıldığı seyreltme katmanı eklenir. Seyreltme katmanı ile azaltılan ağırlıklarla eğitimi gerçekleştirilir. Daha sonra etkisiz bırakılan nöronlar tekrar eski ağırlıklarıyla beraber ağıya yerleştirilir. Seyreltme katmanı ile modelin genelleşme özelliği artar (Wani vd. 2020).



Şekil 3.23. Derin sinir ağı, **a)** tamamen bağlantılı sinir ağı; **b)** bırakma sonrası tamamen bağlı sinir ağı (Srivastava vd. 2014)

3.5. Transfer Öğrenme

Derin sinir ağlarının eğitimi için kullanılacak veri seti miktarının az olması modelin etkili şekilde eğitimi zorlaştırır ve eğitim verilerini ezberleme sorunu ortaya çıkarabilir. Derin sinir ağlarının aşırı uyum (over-fit) probleminin önüne geçebilmek için transfer öğrenme yöntemi yaygın şekilde kullanılmaktadır (Wang vd. 2020). Bu yöntem, önceden büyük veri setleriyle (örneğin ImageNet, COCO) eğitilmiş modellerin öğrenilmiş ağırlıklarının daha az sayıdaki hedef veri kümesi ile hedef modelin eğitilmesi sürecinde tekrar kullanılabilmesine olanak sağlar. Transfer öğrenmeyle hedef model, sıfırdan eğitim yerine eğitilmiş bir temel ağın öğrendiği ağırlıkların kullanımıyla eğitimi gerçekleştirir. Bu sayede önceden eğitilmiş ağın öğrendiği özellikler, benzer görevi gerçekleştirmek için tasarlanmış başka bir ağı aktarılıp yeniden kullanılır. Böylece hedef modelin eğitim süresi azalırken, az miktarda eğitim verileriyle eğitimi gerçekleştirilecek modellerin doğruluk performansı da artar.

Transfer öğrenme, özellik çıkarıcı bölümü sabitlenmiş önceden eğitilmiş model kullanımı veya ince ayarlı tüm model kullanımı olmak üzere iki yaklaşım ile kullanılabilir. Birinci yaklaşımda önceden eğitilmiş ağırlıklar görüntüden özellik çıkarmak için doğrudan kullanılırken son tamamen bağlı katman (sınıflandırıcı katman) hedef göreve göre değiştirilir ve sadece bu son katmanın hedef veri setiyle eğitimi gerçekleştirilir. Böylece modelin özellik çıkarma katmanları sabit kalırken sadece sınıflandırıcı katmanına ince ayar yapılır. Bu yöntem genellikle hedef veri setinin az olduğu fakat orijinal veri setine benzer olduğu durumlarda etkili olmaktadır. İkinci yaklaşımda ise, tamamen bağlı son katman (sınıflandırıcı katman) yeni tam bağlı katmanla değiştirilir ve geri yayılma ile tüm ağ hedef veri setiyle yeniden eğitilir. Bu yöntemde modelin her katmanının parametreleri güncellenir (Wang vd. 2020; Wani vd. 2020).

3.6. Derin Öğrenme Modellerinin Eğitiminde Kullanılan Büyük Veri setleri

3.6.1. ImageNet

Imagenet bilgisayarla görü ve derin öğrenme araştırmalarının gelişiminde etkili olan büyük bir görüntü veri tabanıdır. Veri seti 1000 sınıfa dağıtılmış yaklaşık 1.2 milyon etiketli görüntü içermektedir. 2010 yılından itibaren her yıl derin öğrenme modellerinin ImageNet veri setine dayalı olarak nesnelerin algılanması ve görüntü sınıflandırması için rekabet ettiği ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge; ILSVRC) düzenlenmektedir. Yarışmayı kazanan bazı ESA mimarilerinin ağırlıkları kaydedilir ve bu ağırlıklar transfer öğrenme yöntemleriyle beraber yeni görevlerin hızlı ve az veriyle gerçekleştirilmesini sağlar (Russakovsky vd. 2015).

3.6.2. COCO (The Common Objects in Context)


Microsoft tarafından geliştirilen COCO modellerin bilgisayarlı görüdeki (nesne algılama, nesne/örnek bölütleme gibi) performanslarını kıyaslamak için yaygın şekilde kullanılan veri setidir. Bu veri seti, el yordamıyla bölütlenmiş 2.5 milyon nesne örneği ile 328,000'den fazla görüntü içerir. COCO, ImageNet veri setinden daha az nesne kategorisine sahiptir fakat kategori başına daha fazla örnek içerir (Russakovsky vd. 2015).

3.7. ESA Mimarileri

3.7.1. LeNet

Lecun ve ark. (LeCun vd. 1990) 1990 yılında el yazısı karakteri tanıma amacıyla önerdikleri ESA mimarisini (LeCun vd. 1998) geliştirerek 1998 yılında yayınladıkları bir makalede LeNet-5 ismiyle tanıtmışlardır. Bu model, evrimsel sinir ağ uygulamalarının ilk başarılı çalışması olarak bilinir ve posta kodlarının veya rakamların okunması gibi alanlarda başarıyla uygulanmıştır. Ancak o dönemlerde yüksek bilgi işlem yapabilen makinelerin henüz yaygın olmaması modelin kullanımını kesintiye uğratmıştır (Dhruv ve Naskar 2020).


LeNet-5 modeli görüntü sınıflandırma problemlerine uygulanan bir ESA mimarisidir. Şekil 3.24'teki LeNet-5 modeli, 32*32*1 gri tonlamalı görüntülerle temsil edilen bir dizi el ile yazılmış 0 ile 9 arasındaki rakamları ayırt edebilmek için eğitilmiştir. Modelin gizli katmanı Şekil 3.24'te gösterildiği gibi iki evrim katmanından, iki ortalama havuzlama katmanından ve iki tamamen bağlı katmandan oluşmuştur. Modelin gizli katmanlarında tanh aktivasyon fonksiyonu kullanılırken sınıflandırma katmanında softmax aktivasyon fonksiyonu kullanılmıştır (Xu vd. 2019).



Şekil 3.24. LeNet mimari yapısı (Xu vd. 2019)

3.7.2. AlexNet

Krizhevsky ve ark. 2012 yılında LeNet modeline göre daha derin evrişimli bir sinir ağı olan AlexNet adlı modeli önermişlerdir (Krizhevsky vd. 2012). AlexNet modeli aynı yıl 1000 farklı kategoriden 1.2 milyon doğal görüntü içeren ImageNet veri setinde başarıyla eğitilerek 2012 yılı ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasını %15.3 oranında bir sınıflandırma hatası elde ederek kazanmıştır. AlexNet mimarisi, Şekil 3.25'te gösterildiği gibi beş evrişimli katman, üç maksimum havuzlama katmanı, üç tam bağlı katman ve sınıflandırma için softmax katmanı ile 60 milyon parametre, 650,000 nöron ve 630 milyon bağlantı içerir. Mimari de her bir evrişim ve tam bağlı katmandan sonra ReLU aktivasyon fonksiyonu kullanılmıştır (Rehman vd. 2020).




Şekil 3.25. AlexNet mimari yapısı (paralel iki GPU bölümlere ile) (Krizhevsky vd. 2012)

3.7.3. VGGNet

Simonyan ve ark. tarafından önerilen evrişimli sinir ağı VGGNet (Simonyan ve Zisserman 2014) 2014 yılındaki ILSVRC yarışmasında ikinci olmuştur. VGGNet, 16 ila 19 katman içerebilmektedir. Şekil 3.26'da gösterilen VGGNet'in mimari yapısı AlexNet mimarisine benzerlik gösterse de AlexNet'in evrişimli katmanlarında kullandığı 11*11, 5*5 boyutundaki filtreler yerine model, tüm evrişim katmanlarında adım kaydırma büyüklüğü 1 olarak belirlenen 3*3 boyutunda filtreler kullanır. VGGNet, artan derinlikle beraber daha yüksek sınıflandırma ve tanıma doğruluğu sağlamasına rağmen yaklaşık 140


milyon parametreye sahiptir ve AlexNet mimarisinden daha fazla bellek ve hesaplama süresi kullanmaktadır (Shin vd. 2017).



Şekil 3.26. VGGNet mimari yapısı (Simonyan ve Zisserman 2014)

3.7.4. GoogLeNet

GoogLeNet (ya da Başlangıç V1 (Inception V1)), Szegedy ve ark. tarafından önerilen bir evrişimli sinir ağıdır. Model 2014 yılı ILSVRC yarışmasını kazanmasıyla tanınmıştır. Şekil 3.27’de gösterilen modelin mimarisi toplam 22 katmana sahip olup sinir ağındaki parametre sayısını önemli ölçüde azaltan 9 adet başlangıç (inception) adı verilen modül (farklı boyutlarda filtreler içerir) içerir. AlexNet mimarisinde toplam 60 milyon parametre varken GoogLeNet mimarisinde parametre sayı 4 milyona düşürülmüştür (Hosseini vd. 2020).



Şekil 3.27. GoogLeNet mimari yapısı (Szegedy vd. 2015)

veya aynı sınıfı içeren nesnelerin tespiti, bölütlenmesi ve bunlarla beraber nesnelerin konum bilgisi de elde edilebilir hale gelmiştir (Anonymous 12).

3.8.1. B-ESA

Bölge tabanlı evrişimli sinir ağı anlamına gelen B-ESA, bölge önerilerinde bulunarak nesne algılaması yapan bir algoritmadır. Şekil 3.30'da gösterilen B-ESA mimarisi, görüntü üzerinden nesne tespiti yaparken ilk aşama olarak seçici arama (Selective Search) adı verilen bir algoritma ile görüntü üzerinde yaklaşık 2000 adet bölge önerisinde (nesnenin bulunabileceği) bulunur. İkinci aşamada önerilen bölgelerin her biri belli bir boyuta eşitlenir ve daha sonra ayrı ayrı özellik çıkarımı için bir ESA mimarisinden geçirilir. Son aşamada ise her bir bölge önerisinin ESA mimari çıktısı destek vektör makinesi ile bir doğrusal regresyona verilir. SVM, görüntü üzerindeki nesnenin bölge sınıf tahminini yapar. Doğrusal regresyon ise algılanan nesnenin görüntü üzerinde bulunduğu bölge sınırlarını (koordinat bilgisi) daha kesin şekilde belirleyerek (sınırlayıcı kutuları daraltır) sınırlayıcı kutu tahmininde bulunur. B-ESA mimarisinin, bölge önerilerinin her birinde zaman alıcı ESA özellik çıkarıcının kullanımıyla işlem yükünün artması, gerçek zamanlı nesne tespitinin yapılamaması ve mimarideki üç farklı modelin ayrı ayrı eğitimi gibi sınırlamaları bulunmaktadır. Bu nedenle B-ESA temelinde, Hızlı Bölgesel Evrişimli Sinir Ağı (H B-ESA), DH B-ESA ve Maskeli B-ESA gibi mimariler de geliştirilmiştir (Bharati ve Pramanik 2020; Girshick vd. 2014).




Şekil 3.30. B-ESA mimarisi (Bharati ve Pramanik 2020)

3.8.2. H B-ESA

H B-ESA mimari yaklaşımı B-ESA mimarisi temelinde oluşturulmuş uçtan uca bir eğitim yöntemini prensip alır. H B-ESA'da B-ESA'dan farklı olarak Şekil 3.31'de gösterildiği gibi görüntü üzerinden seçici arama algoritması kullanımıyla önerilen bölgeler ayrı ayrı ESA mimarisinden geçirilmez. Bunun yerine görüntü, özellik haritaları için direkt olarak ESA'ya verilir ve daha sonra bölge öneri tahminleri elde edilir. Görüntüden çıkarılan bölge önerileri RoI havuzlama katmanı aracılığıyla sabit boyuta getirilir ve tamamen bağlı katmana iletilir. H B-ESA, önerilen bölge sınıfının tahmininde SVM yerine softmax aktivasyon fonksiyonunu kullanır. Mimari yaklaşımında, özellik haritası oluşturmak için görüntünün yalnızca bir kere ESA'dan geçirilmesi ve ESA, sınıflandırıcı ve H B-ESA sınırlayıcı kutu regresör eğitiminin tek bir modelde aynı anda eğitilebilmesi gibi artıların olması H B-ESA'nın B-ESA mimarisine göre daha hızlı olmasını sağlamıştır. Mimarideki temel sorun, seçici arama algoritması ile yaklaşık 2000


bölge önerisinde bulunmanın verdiği yavaş süreç oluşumudur (Bharati ve Pramanik 2020; Girshick 2015).



Şekil 3.31. H B-ESA mimarisi (Bharati ve Pramanik 2020)

3.8.3. DH B-ESA


DH B-ESA, 2015 yılında Ren ve ark. tarafından (Ren vd. 2016) önerilmiştir. Önerdikleri mimari’de bölge önerileri için yavaş seçici arama algoritması yerine daha hızlı bölge öneri ağı (Region Proposal Networks-RPN) kullanılmıştır. Şekil 3.32’de gösterilen DH B-ESA mimarisinde ilk olarak bir giriş resmi ESA’da geçirilir ve özellik haritası elde edilir. Daha sonra özellik haritası bölge önerileri için mimaride son evrişimli katmandan sonra eklenen RPN’e iletilir. RPN modülünde, farklı boyutlardaki sınırlayıcı kutuyu temsil eden ilgili çapaların (anchors) oluşturulması ve kayan bir pencere (3*3) ile tüm görüntüye anchorların dağıtılması işlemleri için 3*3 evrişimli katman kullanılır. RPN, görüntünün tamamına dağıtılan sınırlayıcı kutuların nesne içerip içermediğini anlayabilmek için birleşimler üzerinden kesişim (Intersection over Union; IoU) kullanır ve IoU’su 0.7’den büyük olan bir çapa (anchor) nesne içerir (ön plan) IoU’su 0.3’ten küçük olan bir çapa ise nesne içermez (arka plan) olarak sınıflandırılır. Aynı nesnenin birden fazla sınırlayıcı kutusunun olması durumunda maksimum olmayı bastırma (non-maximum suppression) kullanılır. Böylece ilgilenilen bölge sayısı azalır. Sonuç olarak RPN çıktısından nesnellik puanları ile nesne bölge önerileri elde edilir. Bölge önerileri yeniden boyutlandırılmak üzere ilgili bölge (region of interest; RoI) havuzlama katmanına ve daha sonra yeniden şekillenen bölge önerileri bazı tamamen bağlı katmanlara iletilir. Son olarak çıktılar nesne sınıf tahmini için softmax katmanı ile nesnenin tam konum tahmini için sınırlayıcı kutu regresörüne iletilir (Bharati ve Pramanik 2020; Kaldera vd. 2019).



Şekil 3.32. DH B-ESA mimarisi (Ren vd. 2016)

3.8.4. Maskeli B-ESA

DH B-ESA ile nesnelerin sınıf ve konum bilgileri elde edilebilirken görüntüde piksel düzeyinde bölütleme sağlanamamaktadır. Bu nedenle örnek bölütleme (instance segmentation) için Maskeli B-ESA mimarisi geliştirilmiştir (Bharati ve Pramanik 2020; Girshick vd. 2014). Maskeli B-ESA mimarisi Şekil 3.33'te gösterildiği gibi özellik çıkarımı, bölge öneri ağı (region proposal network; RPN), ilgi bölgesi sınıflandırıcı (region of interest classifier) ve sınırlayıcı kutu regresörü (Bounding Box Regressor; BBR) ve son olarak bölütleme maskesi (segmentation mask) olmak üzere farklı görevler içeren adımlardan oluşur (Masood vd. 2020). Maskeli B-ESA mimarisi, nesne tespiti yapan DH B-ESA mimari yapısı ile her bir ilgi bölgesine uygulanan tamamen bağlı ağ yapısının kullanımıyla elde edilen anlamsal bölütlemenin genel olarak birleşimidir. Maskeli B-ESA, DH B-ESA mimarisinde olan RoI havuzlama katmanı yerine piksel düzeyinde bölütlemenin daha iyi hizalanması için çift doğrusal enterpolasyon yöntemi kullanan RoI hizalama katmanı (RoI Align; RoIAlign) içerir (Bharati ve Pramanik 2020).




Şekil 3.33. Maskeli B-ESA mimarisi (özellik çıkarımı için özellik piramit ağı (Feature Pyramid Network; FPN) omurgasına sahip ResNet-101 mimarisi kullanılmıştır) (Ren vd. 2016)

3.9. Derin Öğrenme Modellerinde Kullanılan Hiperparametreler ve Optimizasyon Yöntemleri

3.9.1. Aktivasyon fonskiyonları

Derin sinir ağ katmanlarındaki her bir nöronunda, bilgiler üç temel adımda işlenir. Bu adımlar sırasıyla, bilgilerin ilişkili ağırlıklarla çarpılarak toplanması, toplam sonucuna bir bias değerinin eklenmesi ve son olarak elde edilen sonucun nöronla karakterize bir aktivasyon fonksiyonundan geçirilmesi işlemleridir. Bir derin sinir ağında nöronlar çıktı bilgilerini ileri yayılma ile diğer katmanlardaki nöronlara aktarırken, geriye yayılım (back-propagation) ile modelin çıktı hata değerine bağlı olarak sinir ağındaki nöron ağırlıkları ve bias değerleri güncellenir. Derin öğrenme modellerinde kullanılan aktivasyon fonksiyonları bilginin doğrusal olarak işlenmesinin önüne geçerek bilginin doğrusal olmayacak şekilde işlenmesini sağlar. Bu sayede model verilerden daha karmaşık kalıpları öğrenebilmektedir. Aktivasyon fonksiyonları, bilginin bir nörondan diğer nöronlara iletilip ileilmeyeceğine de karar vermektedir. Derin öğrenme modellerinde aktivasyon fonksiyonu seçilirken model gereksinimleri göz önünde bulundurulur (Anonymous 13). Modellerde sıklıkla kullanılan bazı aktivasyon fonksiyonlarının grafikleri Şekil 3.34’te verilmiştir.



Şekil 3.34. Sinir ağlarında sıklıkla kullanılan aktivasyon fonksiyonları

3.9.2. Eğitim devir sayısı (Epoch)

Eğitim devir sayısı model eğitimi öncesinde belirlenen hiperparametrelerden biri olup, model eğitimi için kullanılacak tüm veri setinin ileri ve geri yayılımla tüm sinir ağından yalnızca birkez geçirilmesi olarak adlandırılır. Tüm veri setinin sinir ağına verilmesi model eğitim süresini uzatan ve zorlaştıran bir durum olduğu için veri seti belirli sayıda gruplara ayrılır. Böylece model tüm veri setini veri grupları üzerinden parçalı olarak hızlı şekilde işler ve ağ ağırlıklarını günceller. Model hiperparametrelerinden bir diğeri ise tek bir veri grubu içerisindeki toplam örnek sayısı miktarını ifade eden batch

size'dır. Batch size (yığın boyutu) ve devir sayısı ile ilişkili olan iterasyon kavramı ise bir devir sayısı için gerekli olan batch sayısıdır (Anonymous 14). İterasyon sayısının hesaplanmasına bir örnek verilirse, 1000 örnek içeren bir veri setinin 200'lük yığınlar (batches) halinde bölünmesi durumunda bir devirin tamamlanabilmesi için model toplam 5 iterasyona ihtiyaç duyar. Model eğitimi için ideal devir sayısı veri setine ve model mimarisine göre seçilebilmektedir. Bu sayının artırılması model başarısına çoğunlukla olumlu yönde etki gösterse de bazı durumlar model başarısını düşürebilmektedir. Bu nedenle model eğitim grafiklerine bakılarak eğitim belli bir devir sayısından sonra durdurulmalıdır (Anonim 1).

3.9.3. Öğrenme hızı (Learning Rate)

Derin sinir ağ modelleri optimizasyon algoritmaları kullanılarak eğitilir ve geriye yayılma sürecinde türev işlemleriyle ağırlıklarının ve bias değerlerini toplam hata değerinin minimum olması için günceller. Öğrenme hızı, model ağırlıklarının hata gradyanına (loss gradient) bağlı olarak ne kadar değiştirilmesi gerektiğini kontrol eden bir hiperparametredir. Bir başka ifadeyle öğrenme hızı, hatayı yerel minimum noktasına ulaştırmak için atılan adımların boyutunu belirleyen parametredir. Öğrenme hızının düşük veya yüksek seçilmesi modelin en iyi doğruluğa (yerel minimum düzeyine) ulaşma hızını bir başka ifadeyle öğrenme hızını etkilemektedir. Öğrenme hızının düşük seçilmesi, model öğrenme hızını ve gradyan azalmasını (gradient descent) yavaşlatırken, öğrenme hızının aşırı yüksek seçilmesi gradyan inişinin minimum noktayı aşmasına neden olabilmektedir (Anonymous 15). Şekil 3.35'te farklı öğrenme hızlarının artan devir sayısı ile beraber hata fonksiyonu üzerindeki etkisi gösterilmektedir. Model için belirlenen iyi öğrenme hızı, model hata fonksiyonunu minimum noktaya daha az devir sayısı ile yaklaştırırken model için belirlenen yüksek öğrenme hızı Şekil 3.35'te görüldüğü gibi devir sayısının artışına rağmen hata fonksiyonunun minimum noktaya ulaşmasını engellemiş ve belli bir değerde sabitlemiştir.



Şekil 3.35. Öğrenme hızının artan eğitim turuna bağlı olarak hata değerine etkisi (Anonymous 16)

3.9.4. Optimizasyon algoritmaları

Optimizasyon algoritmaları model parametrelerinin optimum değerleri için geriye yayılımla güncellenmesini sağlayarak hata (maliyet) fonksiyonunun küresel (global) minimum değere ulaşmasında ve modelin daha iyi öğrenmesinde etkili olan araçlardır. Bu algoritmalar, modellerin hata fonksiyonunun mümkün olan minimum değere ulaşmasında ve model doğruluğunun mümkün seviyede artırılmasından sorumludur. Derin sinir ağ modellerinin performansını iyileştiren algoritmalarından bazılarını örnek olarak Gradyan İnişi (Gradient descent; GD), Adaptif Gradyan Algoritması (Adaptive Gradient Algorithm; AdaGrad), RMSProp ve Adam verilebilir (Anonymous 15).

Gradyan iniş optimizasyon algoritması, Yığınlı Gradyan İnişi (Batch Gradient Descent; BGD), SGD ve Mini Yığın Gradyan İnişi (Mini Batch Gradient Descent; MBGD) olmak üzere üç türe ayrılır. BGD optimizasyon algoritması, kayıp fonksiyonunun minimum değere ulaşması için tüm veri setini kullanarak gradyan hesabı yapar ve geriye yayılımla ağırlıkları ve bias değerlerini günceller. SGD optimizasyon algoritması, her eğitim turu başına veri setindeki her örnek için gradyan hesabı yaparak optimum değere ulaşmayı hedefler. SGD'nin, minimum değere ulaşması için BGD'ye göre daha fazla iterasyon yapması gereklidir. Aynı zamanda bir eğitim turunu tamamlaması için geçen süre de BGD'ye göre daha uzundur. MBGD optimizasyon algoritması ise SGD ile benzer olup veri setindeki her bir örnek yerine küçük gruplar veya yığınlar üzerinde gradyan hesabı yapar. Gradyan iniş optimizasyon algoritmalarının seçiminde eğitim veri setinin büyüklüğü önemli rol oynar (Anonymous 17).

Derin öğrenme modellerinde kullanılan bir diğer optimizasyon algoritması Uyarlamalı Optimizasyon Algoritmasıdır (Adaptive Optimization Technique). Bu algoritmalar gradyan iniş algoritmalarından farklı olarak model eğitim sürecinde başlangıçta belirlenen (genellikle 0.001) öğrenme hız hiperparametre değerini güncelleme yeteneğine sahiptir. Adaptif optimizasyon algoritmalarına örnek olarak AdaDelta, AdaGrad, RMSProp ve Adam gibi algoritmalar örnek olarak verilebilir. AdaGrad optimizasyon yöntemi, kare gradyanların hareketli toplamını tutar ve öğrenme hızını önceki gradyanlara göre parametrelere uyarlar. Ancak yöntemde öğrenme hız küçülme problemi bulunur. AdaDelta optimizasyon yöntemi, azalan öğrenme hızı problemini ortadan kaldıran AdaGrad uzantısıdır. RMSProb optimizasyon yönteminde öğrenme hızı otomatik şekilde ayarlanır ve her parametre için farklı bir öğrenme hızı seçilir. Yöntem, öğrenme hızını tüm geçmiş kare gradyanların üssel (exponentially) azalan ortalamasına bölerek oluşturur. Adam optimizasyon algoritması momentum ve RMSprob optimizasyon algoritmalarının bir kombinasyonu olarak görülebilir. Adam, öğrenme hızını ölçeklendirmek için üstel hareketli ortalamasını uygular ve geçmiş gradyanların üssel olarak azalan ortalamasını tutar (Anonymous 18); (Anonymous 19).

3.10. Model Performansını Değerlendirme Metrikleri

3.10.1. Sınıflandırma problemlerinde kullanılan değerlendirme metrikleri

Model performansının nicelik bakımından değerlendirilebilmesi için doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall), F1-skoru (f1-score) gibi metriklerden yararlanır. Bu metrikler, karmaşıklık matrisinde TP, TN, FP ve FN ile ifade edilen tanımların değerlerinden faydalanılarak hesaplanır.

- **Gerçek Pozitif (True Positive-TP):** Gerçekte pozitif olan bir parametrenin (hasta vb.) model tarafından da pozitif olarak (hasta vb.) tahmin edilmesidir.
- **Gerçek Negatif (True Negative-TN):** Gerçekte negatif olan bir parametrenin (hasta değil vb.) model tarafından da negatif olarak tahmin edilmesidir.
- **Yanlış Pozitif (False Positive- FP):** Gerçekte negatif olan bir parametrenin (hasta değil vb.) model tarafından pozitif olarak (hasta vb.) tahmin edilmesidir.
- **Yanlış Negatif (False Negative- FN):** Gerçekte pozitif olan bir parametrenin (hasta vb.) model tarafından negatif olarak (hasta değil vb.) tahmin edilmesidir.

		Tahminlenen Değer	
		Pozitif (1)	Negatif (0)
Gerçek Değer	Pozitif (1)	True Pozitive (TP)	False Negative (FN)
	Negatif (0)	False Pozitive (FP)	True Negative (TN)

Şekil 3.36. Karmaşıklık matrisi

- **Doğruluk (Accuracy):** Model tahmininin doğruluk yüzdesini veren bir metriktir. Denklem 3.5'te gösterildiği gibi modelin doğru tahminlerinin toplamının (TP ve TN) tüm tahminlerin toplamına (TP, FP, TN ve FN) oranı olarak ifade edilir.

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.5)$$

- **Hassasiyet (Precision):** Modelin pozitif olarak tahmin ettiklerinden kaçının gerçekten pozitif olduğunu gösteren bir orandır. Denklem 3.6'da gösterildiği gibi, model gerçek pozitif tahmininin (TP), modelin tüm pozitif tahminlerinin toplamına (TP ve FP) oranı olarak ifade edilir.

$$\text{Hassasiyet (Precision)} = \frac{TP}{(TP + FP)} \quad (3.6)$$

- **Duyarlılık (Recall):** Modelin gerçekte pozitif olan değerler arasından kaçını doğru pozitif olarak tahmin ettiğini gösteren bir metriktir. Denklem 3.7'de gösterildiği gibi modelin gerçek pozitif tahmin değerinin gerçek pozitif ve yanlış negatif tahmin toplamına oranı olarak ifade edilir.

$$\text{Duyarlılık (recall)} = \frac{TP}{(TP + FN)} \quad (3.7)$$

- **F1 Skoru:** Denklem 3.8'de gösterildiği gibi hassasiyet (precision) ve duyarlılık (recall) metrik değerlerinin harmonik ortalamasıyla hesaplanır.


$$F1 \text{ skoru} = \frac{2 \times \text{hassasiyet} \times \text{duyarlılık}}{(\text{hassasiyet} + \text{duyarlılık})} \quad (3.8)$$

3.10.2. Bölütleme problemlerinde kullanılan değerlendirme metrikleri

Görüntülerden nesne tespiti, sınıflandırılma, bölütleme ve lokalizasyonu ile ilgili çalışan modellerin sonuçlarının değerlendirmesinde precision (hassasiyet), recall (duyarlılık), accuracy (doğruluk), birleşim üzerinden kesişim (Intersection over Union; IoU) değerlendirme metriklerinden yararlanılır.

- **Birleşim Üzerinden Kesişim (Intersection-over-Union - IoU):** Model tarafından önerilen bölge önerilerinin görüntüdeki nesnenin bulunduğu konum için kabul edilir olup olmadığını ölçmeye yardımcı olan bir metriktir. IoU, tahmin edilen bölge ile gerçek referans değer arasındaki örtüşmeyi değerlendirir. Denklem 3.9’da gösterildiği gibi formülize edilir.

$$IoU = \frac{\text{alan}(\text{gerçek referans değer} \cap \text{tahmin edilen})}{\text{alan}(\text{gerçek referans değer} \cup \text{tahmin edilen})} \quad (3.9)$$



Şekil 3.37. IoU’nun resim ile gösterimi

Gerçek referans değer, nesnenin görüntüde bulunduğu yeri gösteren bir etikettir. Model bu bölgenin referansında bölge önerilerinde bulunur ve bu bölge önerilerinin geçerliliğinde IoU eşik değeri göz önünde bulundurulur. IoU eşik değeri 0.5 olarak düşünülürse, IoU değeri 0.5’in altında olan bölge önerileri yanlış tespit yani yanlış pozitif (FP) olarak değerlendirilir. Bu eşikten büyük olan bölge önerileri ise doğru tespit yani doğru pozitif (TP) olarak kabul edilir. IoU değeri 0 olan bölge önerilerinde ise ilgili gerçek zemin maskesi ile kesişimin olmadığı model tarafından düşünülür fakat önerilen bölge önerisi gerçekte ilgili zemin maskesiyle ilişkilidir bu durum da bu öneri yanlış negatif (FN) olarak ifade edilir. Tümör tespiti için oluşturulan model çalışmalarının değerlendirmesinde precision, recall ve mAP metrikleri de kullanılır.

- **Hassasiyet (Precision):** Denklem 3.10’da gösterildiği gibi gerçek referans değer ile ilişkili bölge önerilerinden geçerli olan (TP) bölge önerilerinin oranını ifade eder.

$$Hassasiyet = \frac{TP}{TP + FP} \quad (3.10)$$

- **Duyarlılık (Recall):** Tüm gerçek referans değerler arasından geçerli olan bölge önerisi oranını ifade eder.


$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.11)$$

- **Ortalama Hassasiyet (Average Precision-AP):** Farklı eşiklerde belirlenen IoU değerleri için 0 ve 1 arasındaki tüm recall değerleri arasındaki precision ortalamasıdır.


3.11. Çalışmada Kullanılan Yazılımlar ve Python Kütüphaneleri

3.11.1. VIA

VGG Görüntü Açıklayıcı (VGG Image Annotator; VIA), görüntü, ses ve video için basit ve bağımsız bir manuel açıklama yazılımıdır (Dutta ve Zisserman 2019). Maskeli B-ESA mimarisi tümör bölgesi tespitinde gerçek referans (ground truth; GT) tümör maskesine ihtiyaç duyar. MR görüntülerinde Şekil 3.38’de gösterildiği gibi tümör bölge sınırlarının gösterilmesi için bir web tarayıcısında çalışan VIA yazılımı kullanılmıştır. VIA yazılımıyla tümör sınırları poligon bölge şeklinde çizilerek Şekil 3.39’da gösterilen tümör çeşitleri için açıklama eklenip son olarak tüm yapılan işlemler .json formatlı bir dosyada kaydedilmiştir.



Şekil 3.38. VIA görüntü açıklayıcı yazılımı ile bir görüntü için gerçek referans maskesi oluşturma



Şekil 3.39. VIA aracı ile gerçek referans maskesi oluşturulmuş MR görüntüleri, **a)** meninjiyom; **b)** gliom; ve **c)** hipofiz tümörü

3.11.2. Python

Python 1990'lı yılların başında Guido van Rossum tarafından geliştirilen açık kaynak kodlu, dinamik olarak yazılmış, yorumsal, nesne yönelimli, ayrıca yazılım geliştirme ve veri analizinde öne plana çıkmış üst düzey bir programlama dilidir. Python, söz dizimi kolay anlaşılır, sade bir programlama dilidir ve Windows, Linux, Mac gibi farklı platformlarda da çalışabilmektedir (Anonim 2). Bu çalışmadaki kodlar Python paketinin "3" sürümü ile yazılmıştır.

3.11.3. Numpy

Numpy (Numerical Python), bilimsel hesaplamalar için kullanılan Python kütüphanelerinden bir olup, yüksek performanslı çok boyutlu bir dizi nesnesi ve bu dizilerle çalışmak için araçlar sağlayan bir kütüphanedir. Numpy kütüphanesi kullanılarak bu çalışmada doğrusal cebirsel işlemler, diziler üzerinde matematiksel ve mantıksal işlemler, Fourier dönüşümleri gibi işlemler gerçekleştirilmiştir (Anonymous 20).

3.11.4. Scikit-plot

Makine öğrenme algoritmalarının eğitim sonuçlarını görselleştirmek için kullanılan matplotlib tabanlı bir Python kütüphanesidir. Çalışmada geliştirilen ağ mimarilerinin performans görüntülemeleri için kullanılmıştır.

3.11.5. Tensorflow

TensorFlow, Google Brain ekibi tarafından geliştirilen yüksek performanslı sayısal hesaplamalar ile makine öğrenmesi için kullanılan açık kaynaklı bir yazılım kütüphanesidir (Anonymous 21). Çalışmamızda Tensorflow 1.15.2 sürümü geliştirilen DL ağlarının eğitilmesi esnasında yapılan tensör işlemleri için kullanılmıştır.

3.11.6. Keras

Keras, makine öğrenimi platformu TensorFlow üzerinde çalışan, Python'da yazılmış bir derin öğrenme aplikasyon ara birimidir (Anonymous 22). Çalışmamızda Keras sürümü olarak 2.3.1 kullanılmıştır.

4. BULGULAR


Bu tez çalışmasında, Maskeli B-ESA (He vd. 2017) mimarisini kullanan bir açık kaynak kodu (Abdulla 2017) kullanılarak MR görüntüleri üzerinden beyin tümörü sınıflandırması ve segmentasyonu yapabilen derin yapay sinir ağı mimarileri irdelenmiştir. Çalışma kapsamında, Maskeli B-ESA mimari omurgası olarak önceden COCO (Lin vd. 2014) ve ImageNet (Russakovsky ve Fei-Fei 2010) veri setleriyle eğitilmiş ResNet-50 ve Resnet-101 (He vd. 2016) mimarileri ele alınmıştır. Model eğitimi için görüntüler el yordamıyla VIA aracı (Dutta ve Zisserman 2019) ile GT referansında etiketlenmiş ve her görüntünün sınıf ve segmentasyon bilgisi “.json” formatlı bir dosyada kaydedilmiştir.

4.1. Veri Seti Oluşturma

Çalışma kapsamında halka açık bir görüntü veri seti olan Figshare beyin MR görüntüleri kullanılmıştır (Cheng 2017). Veri seti, Çizelge 4.1’de görüldüğü gibi, meninjiyom (708 kesit), gliom (1426 kesit) ve hipofiz tümörü (930 kesit) olmak üzere üç tip tümör içeren 233 hastanın 3064 adet T1 ağırlıklı (kontrastlı) beyin MR görüntülerinden oluşmaktadır. Tümör çeşitleri, sağıtal (1025 görüntü), aksiyel (994 görüntü) ve koronal (1045 görüntü) olmak üzere üç farklı düzlemde kaydedilmiştir (Çizelge 4.1 ve Şekil 4.1). Veri seti, Figshare web sitesinde (https://figshare.com/articles/dataset/brain_tumor_dataset/1512427) 3064 adet MATLAB “.mat” formatıyla sunulmuş olup, her dosyada tümör etiketi (meninjiyom için 1, gliom için 2 ve hipofiz tümörü için 3), hasta ID’si, 512*512 boyutunda görüntü verileri (uint16 formatında), tümör sınırlarını içeren koordinat bilgisi ve son olarak tümör bölgesini 1 olarak gösteren ikili görüntü bilgisi depolanmıştır.


Çizelge 4.1. Figshare Beyin Tümörü (FBT) veri seti kesitsel düzlemlerdeki dağılımı

Tümör Sınıfı	Hasta sayısı	Görüntülerdeki kesit sayısı	Toplam kesit sayısı
Meninjiyom	82	Aksiyel: 208	708
		Sağıtal: 268	
		Koronal: 232	
Gliom	89	Aksiyel-494	1426
		Sağıtal-439	
		Koronal-493	
Hipofiz	62	Aksiyel-291	930
		Sağıtal-320	
		Koronal-319	




Şekil 4.1. FBT veri setinin kesitsel düzlemlerdeki dağılımını gösteren pasta grafiği


Öncelikle, veri setindeki her bir “.mat” dosyasından görüntü kesitleri ve kesitlerin ikili tümör maskeleri önce Python programlama dili ile yazılan bir kod kullanılarak çıkartıldı ve “.jpeg” formatında kaydedildi. Daha sonra tüm veri setinin tümör bölge sınırlarının VIA aracı ile el yordamı ile doğru şekilde işaretlenebilmesi için her görüntünün ikili tümör maskesi (Şekil 4.2-4(b)) renklendirildi ve Şekil 4.2-4(c)’deki gibi görüntü üzerinde gösterildi. Şekil 4.2-4(c)’deki görüntü referansında görüntülerdeki tümör sınırları VIA aracı kullanarak çizildi.



Şekil 4.2. Veri setindeki 13. ".mat" dosyasının aksiyel düzlemde meninjiyom tümör örneği: **a)** MR görüntüsü; **b)** ikili tümör bölge görüntüsü; **c)** tümör bölgesinin resim üzerinde renklendirilen görüntüsü



Şekil 4.3. Veri setindeki 719. ".mat" dosyasının aksiyel düzlemde gliom tümör örneği: **a)** MR görüntüsü; **b)** ikili tümör bölge görüntüsü; **c)** tümör bölgesinin resim üzerinde renklendirilen görüntüsü



Şekil 4.4. Veri setindeki 1336. ".mat" dosyasının aksiyel düzlemde hipofiz tümörü örneği: **a)** MR görüntü; **b)** ikili tümör bölge görüntüsü; **c)** tümör bölgesinin resim üzerinde renklendirilen görüntüsü



Toplam 3064 MR tümör görüntüsü içeren veri seti önce rastgele şekilde karıştırıldı ve bu karıştırılan düzen kabulünde Figshare Beyin Tümör (FBT) veri seti k -kat ($k=4$) çapraz doğrulama (k -fold cross validation) tekniği kullanımıyla %75'i eğitim (2298), %25'i (766) test olmak üzere 4 farklı sete ayrıldı. Bu setler üzerinden eğitim ve test işlemleri gerçekleştirilen ResNet50/ImageNet mimarisinin sınıflandırma başarı oranları her bir çapraz katlı için ayrı ayrı Çizelge 4.2'de gösterildi. Yapılan ön çalışmada her bir setin model başarısının hemen hemen aynı olduğu gözlemlendiğinden Çizelge 4.3'te eğitim-test dağılımı ve Şekil 4.5'te bu dağılımın pasta grafikleri verilen 1. çapraz katlı (cross-fold) kabulünde mimarilerin eğitim ve test işlemleri gerçekleştirildi.

Çizelge 4.2. FBT veri seti üzerinden 4 kat çapraz doğrulama sonuçları

ResNet-50/Imagenet Eğitim verisi (2298 kesit) Test verisi (766 kesit) 1000 eğitim turu için	1. çapraz katlı (cross fold)	2. çapraz katlı (cross fold)	3. çapraz katlı (cross fold)	4. çapraz katlı (cross fold)
Eğitim veri seti üzerinden sınıflandırma başarı oranı	%94	%91	%92	%93
Test veri seti üzerinden sınıflandırma başarı oranı	%87	%79	%85	%84
Tümör bölgesi bulunan eğitim veri setindeki başarı oranı	%97.47	%97.08	%96.20	%96.64
Tümör bölgesi bulunan test veri setindeki başarı oranı	%93.42	%91.23	%93.40	%91.89
Tümör bölgesi bulunmayan kesit görüntü sayısı	Eğitim	Test	Eğitim	Test
Meninjiyom (1) tümörü için	20	18	7	6
Tümör bölgesi bulunmayan kesit görüntü sayısı	Eğitim	Test	Eğitim	Test
Gliom (2) tümörü için	36	14	109	86
Tümör bölgesi bulunmayan kesit görüntü sayısı	Eğitim	Test	Eğitim	Test
Hipofiz (3) tümörü için	25	19	23	12


Çizelge 4.3. Deneysel çalışmada kullanılan FBT veri setinin tümör türlerindeki dağılımı

Tümör Türü	Eğitim	Test	Toplam
Meninjiyom	528	180	708
Gliom	1083	343	1426
Hipofiz	687	243	930
Toplam	2298	766	3064

**(a)****(b)****Şekil 4.5.** FBT veri setinin tümör sınıflarındaki dağılımını gösteren pasta grafikleri: **a)** eğitim veri seti dağılımı; **b)** test veri seti dağılımı

4.2. Veri Setindeki Görüntülerin VIA ile Etiketlenmesi

Maskeli B-ESA mimarisi tümör bölgesi tespiti yaparken Gerçek Referans (Ground Truth; GT) tümör maskesinin önceden oluşturulmuş olmasını gerektirir. MR görüntülerinde tümör bölge sınırlarının el yordamıyla çizimi için bir web tarayıcısı üzerinde çalışan VIA yazılımı kullanıldı (Dutta ve Zisserman 2019). Bu yazılımla tümör sınırları poligon olarak çizildi ve çizilen alan açıklaması olarak tümör türü eklendi. Son olarak tüm yapılan işlemler hem eğitim veri seti için hem de test veri seti için ayrı olarak .json formatlı bir dosyada kaydedildi. Bu süreçte örnek olarak Şekil 4.6-8'deki görüntüler verilebilir.




(a)

```
"Hasta_1010161.00013.jpg10752":{
  "filename":"Hasta_1010161.00013.jpg",
  "size":"10752",
  "regions":[
    {
      "shape_attributes":{
        "name":"polygon",
        "all_points_x": [301,320,334,342,...
        "all_points_y": [323,317,308,297,...
      },
      "region_attributes":{"name":"meningioma"}}],
      "file_attributes":{}
    }...
  }
```

(b)

Şekil 4.6. Veri setindeki 13. ".mat" dosyasının aksiyel düzlemde meninjiyom tümör örneği: **a)** VIA aracı ile tümör sınırlarının gösterimi; **b)** .json format ile gösterimi




(a)

```
"Hasta_1010202.00719.jpg18388":{
  "filename":"Hasta_1010202.00719.jpg",
  "size":"18388",
  "regions":[
    {
      "shape_attributes":{
        "name":"polygon",
        "all_points_x": [286,297,307,320,...
        "all_points_y": [310,303,295,293,...
      },
      "region_attributes":{"name":"glioma"}}],
      "file_attributes":{}
    }...
  }
```

(b)

Şekil 4.7. Eğitim veri setindeki 719. ".mat" dosyasının aksiyel düzlemde gliom tümör örneği: **a)** VIA aracı ile tümör sınırlarının gösterimi; **b)** .json format ile gösterimi



(a)

```
"Hasta_1037313.01336.jpg23393":{
  "filename":"Hasta_1037313.01336.jpg",
  "size":"23393",
  "regions":[
    {
      "shape_attributes":{
        "name":"polygon",
        "all_points_x": [189,186,190,198,...
        "all_points_y": [250,263,273,282,...
      },
      "region_attributes":{"name":"pituitary"}}],
  "file_attributes":{}
  }...
```

(b)


Şekil 4.8. Veri setindeki 1336. ".mat" dosyasının aksiyel düzlemde hipofiz tümör örneği: **a)** VIA aracı ile tümör sınırlarının gösterimi; **b)** .json format ile gösterimi

4.3. Önerilen Maskeli B-ESA Modelleri

Bu çalışmada Maskeli B-ESA mimarisi altında çalışan bir açık kaynak kodu kullanıldı (Abdulla 2017). Bu kod Şekil 4.9’da görüldüğü gibi dört ayrı bölümden meydana gelir:

1. Görüntülerden özelliklerin çıkarıldığı *Özellik Çıkarımı Bölümü*,
2. Özellik haritaları üzerinden bölge önerilerinin yapıldığı *Bölge Öneri Ağı Bölümü*,
3. Bölge önerilerinin tam bağlı katman girişi için aynı boyuta getirildiği ve bölge önerilerinin sınıflandırma ile regresyon işlemlerinin yapıldığı *ROI Sınıflandırma ve Sınırlayıcı Kutu Regresyonu Bölümü* ve
4. Görüntüde aynı sınıfa ait piksellerin kimliklendirildiği yani maskelendiği *Bölütleme Maskesi Bölümü*

Çalışma kapsamında önerilen Maskeli B-ESA mimarisinde, omurga olarak COCO (Common Objects in Context) ve ImageNet veri setleri ile eğitilmiş (ön eğitilmiş) ResNet-50 ve ResNet-101 ESA mimarileri kullanıldı. Bu mimarilerin son tamamen bağlı katmanı (sınıflandırma) üç sınıf olarak (meninjiyom, gliom ve hipofiz tümörü şeklinde) değiştirildi.



Şekil 4.9. Çalışmada kullanılan Maskeli B-ESA mimarisi (Masood vd. (2020) çalışmasından uyarlanmıştır)

4.4. Modelin Eğitiminde Kullanılan Hiperparametreler

Çalışmada önerilen modellerin eğitimi Çizelge 4.4'te ana hatları verilen hiperparametrelerin kullanımı ile 32 GB Ram bellekli 3.9 GHz Xeon işlemcili bir iş istasyonuna kurulu tek bir grafik işlem birimi (Graphical Processing Unit; GPU) ve Nvidia'nın CUDA (Compute Unified Device Architecture-CUDA) platformunu kullanan GeForce GTX 1050 TI üzerinde gerçekleştirildi.

Model, önceden eğitilmiş iki ağırlık seti ile (COCO ve ImageNet) iki omurga (ResNet-50 ve ResNet-101) olmak üzere toplamda dört farklı mimari kombinasyonunun eğitimi 1000 devir sayısı (epoch) kabulüyle eğitim veri seti (2298 MR görüntüsü) üzerinden gerçekleştirildi. Her bir devir sayısında kaydedilen ortalama eğitim süresi ResNet-50 modelleri için 105 saniye ve ResNet-101 modelleri için 130 saniye'dir. Modellerin 1000 devir sayısı süresince toplam eğitim süresi ise ResNet-50 modelleri için ortalama 29 saat iken ResNet-101 modelleri için ortalama 36 saat'tir. Modellerin her 200 devir sayısında bir modellerin eğitim ağırlıkları .h5 uzantılı bir dosyaya kaydedildi ve elde edilen ağırlıklar ile test veri seti (766 MR görüntüsü) üzerinden önerilen modellerin testleri gerçekleştirildi.

Çizelge 4.4. Önerilen modellerin eğitiminde kullanılan optimize edilmiş parametreler

Hiperparametre	Optimize edilmiş değer
Optimizasyon algoritması	SGD
Eğitim devir sayısı	1000
Yığın boyutu	1
Öğrenme hızı	0.001
Momentum sabiti	0.9

4.5. Model Eğitim ve Test Sonuçları

Çalışmada önerilen modellerin (iki önceden eğitilmiş ağırlık: ImageNet ve COCO; iki omurga: ResNet-50 ve ResNet-101) her 200 devir sayısında kaydedilen ağırlıkları (200, 400, 600, 800 ve 1000 eğitim devir sayısı için) kullanılarak test veri setinin (766 görüntü) üzerinden performans değerlendirmeleri yapıldı. Eğitim veri setindeki her görüntü üzerinde tek bir tümör bölgesi etiketlendi. Önerilen modeller, test veri setindeki görüntüler üzerinde %90 ve üzeri güven puanı ile tümör bölge tespitinde bulunabilmektedir. Çalışmada modellerin tek sınıf içeren test veri setindeki görüntüler üzerinde birden fazla sınıf veya daha fazla bölge önerisinde bulunma durumunun yüksek güven puanıyla azaltılabilesinden dolayı güven puanının minimum değeri %90 olarak belirlendi.

Bu çalışmada birden fazla tümör bölge önerisi yerine, ya tek bir bölge önerisinin kabulü için maksimum güven puanına (maksimum skor) sahip bölge önerisinin alındığı ya da gerçek referans etiketiyle maksimum kesişime sahip bölge önerisinin alındığı iki durum düşünüldü ve bir Python kodu yardımı ile her bir durum için görüntü üzerinde tek bir tümör bölesi gösterildi. Hem maksimum güven puan durumu hem de maksimum kesişim durumu için modellerin performans değerlendirmeleri yapıldı.

Modellerin performans değerlendirmesinde tümör segmentasyon başarısı ve tümör sınıflandırma başarısı olmak üzere iki kriter göz önünde bulunduruldu. Segmentasyon başarı tespiti için IoU (overlap-kesişim) ve mAP metriklerinden faydalandı. Her bir modelin test ve eğitim veri setlerindeki görüntüler üzerinden tümör sınıflandırma performans değerlendirmesi için maksimum skor kabulünde karmaşıklık matrisleri (Confusion matrix) oluşturuldu ve bu matrisler üzerinden Denklem 3.5 ile doğruluk (accuracy), Denklem 3.6 ile hassasiyet (precision), Denklem 3.7 ile duyarlılık (recall) ve Denklem 3.8 ile F1-skor (F1-score) metrikleri hesaplanarak sonuçlar Çizelge 4.3'e kaydedildi.

Modellerin karmaşıklık matrisleri 4*4 boyutunda dört sınıf düşünülerek Şekil 4.10(a)'daki gibi oluşturuldu ve Şekil 4.10(b)'de gösterilen değerlendirme metriklerinin hesaplama formülleri ile bulunan değerler Çizelge 4.4'e kaydedildi. Karmaşıklık matrisleri üzerindeki rakamlar tümör çeşitlerini ve tümörün ilgili model tarafından bulunamama durumunu göstermektedir. Bu etiketlerden "1" Meninjiyom tümörünü, "2" gliom tümörünü, "3" hipofiz tümörünü ve son olarak "4" ise görüntü üzerinde tümör olmasına rağmen modelin tümör sınıflandırmasında bulunamama durumunu simgelemektedir.


Sınıflar		Tahmin edilen sınıf etiketi			
		1	2	3	4
Gerçek sınıf etiketi	1	a	e	f	g
	2	h	b	k	l
	3	m	n	c	p
	4	r	s	t	d

	precision	recall	f1-score	toplaml	accuracy
1	$p1=a/(a+h+m+r)$	$r1=a/(a+e+f+g)$	$f1=2*p1*r1/(p1+r1)$	$t1=a+e+f+g$	$y=(a+b+c+d)/(a+b+c+d+e+f+g+h+k+l+m+n+p+r+s+t)$
2	$p2=b/(e+b+n+s)$	$r2=b/(h+b+k+l)$	$f2=2*p2*r2/(p2+r2)$	$t2=h+b+k+l$	
3	$p3=c/(f+k+c+t)$	$r3=c/(m+n+c+p)$	$f3=2*p3*r3/(p3+r3)$	$t3=m+n+c+p$	
4	0	0	0	0	


(a)
(b)

Şekil 4.10. a) Karmaşıklık matrisi; **b)** çalışmada kullanılan değerlendirme metriklerinin dört sınıf için hesaplamaları


Buna göre Şekil 4.11’de önceden eğitilmiş ResNet-50 omurgası ve başlangıç ağırlığı COCO veri seti olan modelin 1000 eğitim turundaki eğitim ve test veri setleri için karmaşıklık matrisleri; Şekil 4.12’de önceden eğitilmiş ResNet-101 omurgası ve başlangıç ağırlığı COCO veri seti olan modelin 1000 eğitim turundaki eğitim ve test veri setleri için karmaşıklık matrisleri; Şekil 4.13’te önceden eğitilmiş ResNet-50 omurgası ve başlangıç ağırlığı ImageNet veri seti olan modelin 1000 eğitim turundaki eğitim ve test veri setleri için karmaşıklık matrisleri; Şekil 4.14’te önceden eğitilmiş ResNet-101 omurgası ve başlangıç ağırlığı ImageNet veri seti olan modelin 1000 eğitim turundaki eğitim ve test veri setleri için karmaşıklık matrisleri elde edildi. Karmaşıklık matrisleri üzerindeki değerler ile Şekil 4.10(b)’de gösterilen formüller üzerinden ilgili metrikler hesaplandı ve Çizelge 4.3’e kaydedildi.




Şekil 4.11. ResNet-50 omurgası ve **COCO** başlangıç ağırlığı kullanılan modelin **1000** eğitim turunda elde edilen karmaşıklık matris maksimum skor için sonuçları: **a)** eğitim veri seti (2298 görüntü) sonuçları; **b)** test veri seti (766 görüntü) sonuçları



Şekil 4.12. ResNet-101 omurgası ve COCO başlangıç ağırlığı kullanılan modelin 1000 eğitim turunda elde edilen karmaşıklık matris maksimum skor için sonuçları: **a)** eğitim veri seti (2298 görüntü) sonuçları; **b)** test veri seti (766 görüntü) sonuçları



Şekil 4.13. ResNet-50 omurgası ve ImageNet başlangıç ağırlığı kullanılan modelin 1000 eğitim turunda elde edilen karmaşıklık matris maksimum skor için sonuçları: **a)** eğitim veri seti (2298 görüntü) sonuçları; **b)** test veri seti (766 görüntü) sonuçları



Şekil 4.14. ResNet-101 omurgası ve ImageNet başlangıç ağırlığı kullanılan modelin 1000 eğitim turunda elde edilen karmaşıklık matris maksimum skor için sonuçları: **a)** eğitim veri seti (2298 görüntü) sonuçları; **b)** test veri seti (766 görüntü) sonuçları

Çizelge 4.5'te verilen metrik değerlendirme sonuçlarına göre, 1000. eğitim turunda önceden eğitilmiş ResNet-101 omurgası (maksimum skor kabulünde) ve başlangıç ağırlığı COCO olan model, test veri seti üzerinde %75 oranında sınıflandırma doğruluk başarısı gösterirken, önceden eğitilmiş ResNet-50 omurgası ve başlangıç ağırlığı ImageNet olan model ise test veri seti üzerinde %87 oranında sınıflandırma doğruluk başarısı gösterdi. En düşük sınıflandırma başarısı %36 oranında ResNet-101 omurgası ve başlangıç ağırlığı ImageNet olan model ile elde edildi. Sonuç olarak incelenen tüm modeller arasında ResNet-101/COCO ve ResNet-50/ImageNet modelleri en yüksek test doğruluk başarısına sahip model olarak bulundu.

Çizelge 4.5. Maskeli B-ESA mimarileri için sınıflandırma sonuçları (M: Meninjiyom, G: Gliom, H: Hipofiz, Ort.:Ortalama)

Deneyisel çalışma	Eğitim tururu	Sonuçlar															
		Doğruluk %		Hassasiyet				Duyarlılık				F1-skor					
		Eğitim	Test	M	G	H	Ort.	M	G	H	Ort.	M	G	H	Ort.		
COCO + ResNet-50	200	29	31	0.0	0.0	0.35	0.11	0.0	0.0	0.98	0.32	0.0	0.0	0.52	0.17		
	400	46	43	0.45	0.76	0.57	0.59	0.62	0.28	0.51	0.47	0.52	0.41	0.54	0.49		
	600	41	43	0.83	0.65	0.61	0.69	0.24	0.26	0.79	0.43	0.38	0.37	0.69	0.48		
	800	52	48	0.88	0.47	0.84	0.73	0.16	0.95	0.7	0.60	0.26	0.62	0.12	0.33		
	1000	54	55	0.61	0.78	0.75	0.71	0.64	0.42	0.67	0.57	0.63	0.55	0.71	0.63		
COCO + ResNet-101	200	68	65	0.83	0.79	0.90	0.84	0.43	0.75	0.65	0.61	0.57	0.77	0.76	0.70		
	400	77	72	0.78	0.83	0.82	0.81	0.62	0.72	0.81	0.71	0.69	0.77	0.81	0.75		
	600	69	66	0.64	0.97	0.88	0.83	0.87	0.47	0.77	0.70	0.74	0.63	0.82	0.73		
	800	82	77	1.00	0.81	0.78	0.86	0.27	0.92	0.95	0.71	0.43	0.86	0.85	0.71		
	1000	80	75	0.91	0.95	0.84	0.90	0.59	0.74	0.88	0.73	0.72	0.83	0.86	0.80		
ImageNet + ResNet-50	200	70	66	0.97	0.87	0.87	0.90	0.33	0.69	0.85	0.62	0.50	0.77	0.86	0.71		
	400	87	83	0.80	0.96	0.96	0.90	0.90	0.80	0.82	0.84	0.85	0.88	0.88	0.87		
	600	88	80	0.93	0.96	0.91	0.93	0.78	0.76	0.87	0.80	0.85	0.85	0.89	0.86		
	800	91	81	0.93	0.93	0.89	0.91	0.68	0.82	0.90	0.80	0.78	0.87	0.90	0.85		
	1000	94	87	0.97	0.92	0.94	0.94	0.72	0.96	0.86	0.84	0.83	0.94	0.90	0.89		
ImageNet + ResNet-101	200	13	14	0.00	0.0	0.53	0.17	0.1	0.0	0.45	0.18	0.1	0.0	0.49	0.19		
	400	27	27	0.55	1.00	0.50	0.68	0.19	0.0	0.71	0.30	0.29	0.1	0.59	0.32		
	600	34	32	0.46	0.57	0.66	0.56	0.37	0.18	0.47	0.34	0.41	0.27	0.55	0.41		
	800	26	26	0.71	0.0	0.56	0.42	0.22	0.0	0.67	0.29	0.33	0.0	0.61	0.31		
	1000	36	37	0.51	0.76	0.67	0.64	0.39	0.20	0.61	0.4	0.44	0.31	0.64	0.46		

Tez çalışmasında Çizelge 4.5'te gösterilen metriklere ek olarak, sınıflandırma başarısı diğer modellere göre yüksek olduğu tespit edilen (ResNet-101+COCO ve ResNet-50+Imagenet) modellerinin test veri seti üzerinden bölütleme performansları da değerlendirildi. Bu değerlendirme için ilk olarak test veri setindeki MR tümör görüntüleri bir tümör sınıfını temsil eden üç farklı klasöre (gliom: 343 görüntü; meninjiyom: 180 görüntü ve hipofiz: 243 görüntü) yerleştirildi. Her klasördeki görüntünün AP ve IoU (örtüşme-overlap) metrikleri, maksimum güven ve maksimum örtüşme (overlap) skorları ayrı olarak yazılan bir Python koduyla hesaplandı. Son olarak her iki kriter ve her sınıf klasörü için sonuçlar üç ayrı excel dosyası halinde kaydedildi.


Her bir görüntü için hesaplanan AP değerinin, sınıflandırmanın doğru ve örtüşme değerinin 0.5'ten büyük olduğu tahminlerde "1" olduğu ve tümör sınıfının bulunmadığı ya da sınıfın yanlış tahmin edildiği veya örtüşme değerinin 0.5'ten küçük olduğu tahminlerde ise AP değerinin "0" olduğu görüldü. Her tümör sınıfının maksimum skor ve

maksimum örtüşme için AP değerlerinin ortalaması alındı ve Çizelge 4.6'ya kaydedildi. Ortalama IoU değer hesabında ise her tümör sınıfında sadece doğru sınıflandırılmış bölge önerilerinin örtüşme değerleri alındı ve Çizelge 4.6'ya kaydedildi. Son olarak her tümör sınıfının doğruluk değeri de hesaplanarak yine Çizelge 4.6'ya eklendi.


Çizelge 4.6. Maskeli B-ESA modellerinin bölütleme sonuçları (M: Meninjiyom, G: Gliom, P: Hipofiz)

Deneyisel çalışma	Tümör bölge seçme metodu	mAP				IoU				Doğruluk			
		M	G	P	Ort.	M	G	P	Ort.	M	G	P	Ort.
COCO+ResNet-101	Mak. Skor	0.54	0.45	0.81	0.6	0.80	0.53	0.73	0.68	0.57	0.75	0.90	0.74
	Mak.IoU(kesişim)	0.55	0.41	0.78	0.58	0.79	0.50	0.70	0.66	0.59	0.73	0.90	0.74
ImageNet+ResNet-50	Mak. Skor	0.75	0.67	0.80	0.74	0.83	0.57	0.75	0.71	0.75	0.95	0.88	0.86
	Mak.IoU(kesişim)	0.75	0.73	0.80	0.76	0.83	0.58	0.75	0.72	0.75	0.95	0.88	0.86


Veri kümesindeki her görüntü yalnızca bir tümör sınıfı ve tümör bölgesi içermektedir. Bu nedenle, Maskeli B-ESA modeli bir görüntü için tek bir sınırlayıcı kutu önerdiğinde, bu bölge ve sınıf tahmini görüntüye atandı (Şekil 4.15). Maskeli B-ESA modelinin bir görüntü üzerinde aynı sınıf olarak tahminlediği birden fazla bölge önerisi (sınırlayıcı kutu atama ve maskeleme) durumunda görüntü için en yüksek IoU (overlap) ve maksimum skor değerine sahip bölge alınarak Şekil 4.16'da gösterildiği gibi görüntüye atandı. Model tarafından birden fazla bölge önerisinin aynı sınıf olarak tahminlendiği ve maksimum güven puanını atadığı bölgenin IoU değerinin en yüksek olmama durumunda en yüksek örtüşme-kesişim değerine sahip öneri bölgesi alındı (Şekil 4.17). Son olarak model tarafından bölge tahmininde iki farklı bölge ve farklı sınıflar olduğu durumda ise maksimum güven puanına ve kesişime sahip bölge Şekil 4.18'de gösterildiği gibi görüntüye atandı.




Şekil 4.15. Örnek bir görüntü üzerinde tek bir aday bölge için sınıflandırma aşamaları: **a)** etiketli görüntü; **b)** önerilen sınırlayıcı kutu; **c)** seçilen bölge



Şekil 4.16. Örnek bir görüntü üzerinde birden fazla aday bölge için segmentasyon aşamaları: **a)** etiketli görüntü; **b)** önerilen sınırlayıcı kutular; **c)** seçilen bölge (maksimum skor ve maksimum kesişim)



Şekil 4.17. Örnek bir görüntü üzerinde birden fazla aday bölge için segmentasyon aşamaları: **a)** etiketli görüntü; **b)** önerilen sınırlayıcı kutular; **c)** seçilen bölge (maksimum skor); **d)** maksimum kesişim (IoU)




Şekil 4.18. Örnek bir görüntü üzerinde birden fazla aday bölge için segmentasyon aşamaları: **a)** etiketli görüntü; **b)** önerilen sınırlayıcı kutular **c)** seçilen bölge (hem maksimum skor hem de maksimum IoU için aynı)

5. TARTIŞMA

Bu tez çalışmasında beyin tümörlerinin (meninjiyom, gliom ve hipofiz) MR görüntüleri üzerinden sınıflandırma ve bölütleme işlemlerini tek bir çatı altında yapabilen transfer öğrenme yöntemine dayalı derin öğrenme mimari tasarımı amaçlanmış ve bu amaçla açık kaynak kodlu Maskeli B-ESA mimari yaklaşımı kullanılmıştır. Literatürde aynı veri setinin (Figshare) kullanımıyla beyin tümörlerinin sınıflandırılması ve tespiti için farklı bölge tabanlı ESA mimari yaklaşımlarının önerildiği görülmüş fakat bu çalışmalar içinde hem sınıflandırma hem de bölütleme işlemi için Maskeli B-ESA mimari yaklaşımıyla beyin tümörü çalışmalarının sayıca daha az olduğu tespit edilmiştir.

Kaldera vd. (2019) MR görüntüleri üzerinden gliom ve meninjiyom beyin tümörlerinin tam otomatik sınıflandırma problemi için ESA ile beraber sadece meninjiyom beyin tümörlerinin bölütlemesini gerçekleştiren DH B-ESA modelinin kullanımı önerisinde bulunmuşlardır. Çalışmalarında Figshare beyin tümör veri setindeki meninjiyom (119 kesit) ve gliom (138 kesit) tümörlerinin yalnızca aksiyel eksendeki MR görüntü kesitlerini model eğitime dahil etmişlerken, aynı veri setindeki hipofiz tümör görüntüleri model eğitiminde yer almamıştır. Çalışmalarındaki ön işleme aşamasında görüntüler üzerinde önemli özelliklerin kaybını önleyebilmek için boyut küçültme (128*128) ve normalizasyon işlemlerini uygulamışlardır. Önerdikleri mimari Şekil 5.1’de gösterildiği gibi ön işleme, özellik çıkarma ve sınıflandırma için bir ESA modelini ve tümör çıkarma için DH B-ESA mimarisini içermektedir.




Şekil 5.1. Kaldera vd. (2019) tarafında yapılan beyin tümör sınıflandırması ve segmentasyonu çalışması için önerilen model

Çalışmalarında son olarak tam tümör yeri ve alanı için DH B-ESA mimari çıktı görüntülerini tekrar original boyutlara (512*512) eşledikten sonra yalnızca görüntü üzerindeki sınırlayıcı kutuya Prewitt kenar algılama algoritmasını uygulamışlardır. Bu tez çalışmasında da aynı veri seti kullanılmıştır. Ancak veri setinin tamamı (3064 kesit) ".mat" dosyasından çıkarılmış olup, önerilen modelin eğitim ve test veri seti eksen ve tümör tür ayrımı olmadan sırasıyla %75 ve %25 olarak ayrılmıştır. Tez çalışmasında farklı olarak üç tümör türü (meninjiyom, gliom ve hipofiz) için farklı algoritmalara ihtiyaç duyulmadan tek bir ESA mimarisi ile sınıflandırma, bölütleme ve tespit işlemleri gerçekleştirilmiştir. Ayrıca DH B-ESA mimari önerilerinde kullandıkları ImageNet ile


önceden eğitilmiş ESA mimarisine ek olarak bu tez çalışmasındaki COCO veri seti ile önceden eğitilmiş ESA mimarisi de kullanılmıştır.

Bhanothu vd. (2020) çalışmalarında meninjiyom, gliom ve hipofiz beyin tümörlerinin MR görüntüleri üzerinden tespiti ve sınıflandırılması için DH B-ESA derin öğrenme algoritmasını önermişlerdir. Önerdikleri algoritmada, bölge önerisi ve sınıflandırıcı ağ için temel katman olarak VGG-16 mimarisini kullanmışlardır. Çalışmalarındaki beyin tümör görüntüleri Figshare veri setinden alınmış ve bu görüntüler minimum-maksimum metoduyla normalize edilmiştir. Mimarilerinin eğitimi için 1924 görüntü ve testi için 482 görüntü olmak üzere toplam üç sınıfa ait 2406 kesit T1 ağırlıklı kontrastlı MR görüntüleri üzerinden uygulanmıştır. Algoritmalarının sınıflandırma ve tespit sonuçlarına göre gliom için %75.18, meninjiyom için %89.45 ve hipofiz tümörü için %68.18 ortalama hassasiyet değeri elde edilmiştir. Tüm sınıflar için ise ortalama %77.6 oranında ortalama hassasiyet göstermiştir. Bu tez çalışmasında ise Figshare görüntü veri setinin tamamı kullanılmış olup görüntü tespiti ve sınıflandırması diğer tümör çeşitlerine (meninjiyom ve hipofiz) göre daha zor olan gliom tümörünün görüntü sayısı, önerilen mimarinin eğitim ve test veri setlerinde görece daha fazladır. Maskeli B-ESA modelinde temel mimari olarak önceden COCO ve ImageNet ile eğitilmiş ResNet-50 ve ResNet-101 mimarileri önerilmiştir. Maskeli B-ESA ile tespit, sınıflandırma ve bölütleme işlemleri gerçekleştirilmiştir. Önerdiğimiz modellerden ImageNet+ResNet-50 modeli ile tümör bölge seçim metodu maksimum IoU (kesişim) kabulünde meninjiyom için %75, gliom için %95 ve hipofiz tümörleri için %87 doğruluk oranları vermektedir. Her tümör sınıfının önerilen ve etiketlenen bölgelerin oranını temsil eden IoU değerlerinin ortalaması menenjiyoma için %83, gliom için %58 ve hipofiz tümörleri için %75'tir. Son olarak, 0.5 eşikten büyük IoU değerleri için 1 veren metrik olan AP değerlerinin ortalaması (mAP) meninjiyom için %75, gliom için %73 ve hipofiz tümörleri için %80 olarak elde edilmiştir.

Avşar and Salçin (2019) Figshare beyin tümör veri setindeki meninjiyom, gliom ve hipofiz tümörlerinin MR görüntüleri üzerinden tespiti ve sınıflandırılması için Maskeli B-ESA model temelini oluşturan DH B-ESA mimari yaklaşımında bulunmuşlardır. DH B-ESA modelinin kullanımıyla MR görüntüleri üzerinde tespit edilen tümörün sınıf bilgisi, tümörün sınıfa ait olma olasılığı ve tümörün konum bilgisini elde etmişlerdir. Çalışmalarında farklı softmax eşikleri (0.8, 0.66 ve 0.5) kullanarak önerdikleri modelin sınıflandırma doğruluk başarısını her bir tümör sınıfı için değerlendirmişlerdir. Yöntemleriyle literatürdeki diğer önerilen B-ESA modellerine kıyasla %91.66 sınıflandırma doğruluğu sağlamışlardır. Bu çalışmada önerdikleri mimari ile Şekil 5.2'de görüldüğü gibi beyin tümörlerinin lokalizasyonu ve sınıflandırma işlemi gerçekleştirilmiş, bu tez çalışmasında önerilen mimariler ile bu işlemlere ek olarak bölütleme işlemi Şekil 5.3'te görüldüğü gibi gerçekleştirilerek %87 sınıflandırma başarısına ulaşılmıştır.



Şekil 5.2. Avşar and Salçin (2019) tarafından önerilen modelin beyin tümörlerinin tespiti ve sınıflandırması: **a)** meninjiyom; **b)** gliom; **c)** hipofiz tümörü




Şekil 5.3. Bu tez çalışmasında önerilen modelin (ResNet-50+Imagenet model başlangıç ağırlığı ile (maksimum skor kabulünde) beyin tümörlerinin tespiti, sınıflandırması ve bölütlenmesi, **a)** meninjiyom; **b)** gliom; **c)** hipofiz tümörü

Masood vd. (2020) MR görüntüleri üzerinden beyin tümörlerinin (tümör veya tümör olmayan bölgeler) kesin bölütlemesi için ResNet-101 ve özellik piramit ağı (Feature Pyramid Network-FPN) omurgasına sahip Maskeli B-ESA modeli önermişlerdir. Önerilen modellerini COCO veri setinden elde edilen ağırlıklarla başlatmışlardır. Önerdikleri model performanslarını çevrimiçi olarak temin edilebilen iki ayrı veri seti (Brain Tumor Figshare- BTF ve Brain Tumor Kaggle- BTK) üzerinde analiz etmişlerdir. Modelleri ile BTF veri seti üzerinde %95.1 ve BTK veri seti üzerinde %94.6 ortalama doğruluk elde edilmiş ve önerdikleri yöntemin BTF veri setinde 0.952 ve BTK veri setinde 0.948 ortalama hassasiyetle (average precision) beyin tümörünü doğru olarak lokalize ettiği belirtilmiştir. Bu tez çalışmasında önerilen Maskeli B-ESA modellerinin eğitiminde aynı veri setindeki MR beyin tümör görüntüleri kullanılmış ve beyin tümörlerinin lokalizasyonu ve bölütlenmesi işlemleri gerçekleştirilerek önerilen mimariler ile bu işlemlere ek olarak sınıflandırma da yapılmıştır. Ayrıca kullanılan ResNet-101 omurgası ile COCO ağırlıklarına ilave olarak tez çalışmasında ResNet-50 mimari omurgası ve Imagenet ağırlıkları da Maskeli B-ESA mimarisi için önerilmiştir.

Masood vd. (2021) diğer bir çalışmalarında beyin tümörlerinin sınıflandırılması ve segmentasyonu için transfer öğrenme yoluyla eğitilmiş ResNet-50 ve DenseNet-41 olmak üzere iki ayrı omurgaya sahip Şekil 5.4-5'te gösterilen Maskeli B-ESA mimari yaklaşımında bulunmuşlardır. Metotlarını çeşitli nicel ölçümler kullanarak iki farklı veri setinde değerlendirmişlerdir. Önerdikleri DensNet-41 tabanlı Maskeli B-ESA modelinin ResNet-50 omurgasına göre daha iyi bölütleme ve sınıflandırma başarısına sahip olduğunu tespit etmişler ve bölütleme ve sınıflandırmada sırasıyla %96.3 ve %98.34 doğruluk başarısını elde etmişlerdir.



Şekil 5.4. Masood vd. (2021) tarafından önerilen yöntemin blok diyagramı



Şekil 5.5. Masood vd. (2021) tarafından önerilen yöntemin yapısı

Bu tez çalışması ile literatürdeki benzer çalışmaların kıyaslanması sonucunda çalışmada farklı olarak iki farklı omurga (ResNet-50 ve ResNet-101) ve iki ön eğitim ağırlığı (COCO ve ImageNet) kullanıldığı görülmektedir (Şekil 5.6). Önerilen Maskeli B-ESA modelinin MR görüntüleri üzerinden beyin tümörlerini sınıflandırma ve bölütleme performansı değerlendirilirken maksimum güven skoru ve maksimum IoU değerleri ayrı olarak kritize edilmiştir. Önerilen modellerin performans sonuçlarına göre ImageNet veri seti ile önceden eğitilmiş model ağırlığı ile ResNet-50 model yaklaşımının %87 oranında sınıflandırma başarısı elde ettiği gözlenmiştir.



Şekil 5.6. Bu tez çalışması için önerilen modelin blok diyagramı

Masood vd. (2021)'nin çalışmalarına kıyasla bu tez çalışmasında elde edilen beyin tümör sınıflandırma ve bölütleme başarımının daha düşük olduğu görülmüştür. Bunun nedeni olarak Figshare beyin tümör veri setindeki görüntülerin tez çalışmasında herhangi bir ön işleme tabi tutulmadan ham şekilde model eğitiminde kullanılması olduğu düşünülmektedir. Anılan çalışmanın ise ön işleme adımında bias alanı düzeltmesi için seviye seti yöntemini uyguladığı ve MR görüntülerindeki gürültülerin arındırılarak geliştirilmesi için medyan filtresi kullandığı anlaşılmıştır.

6. SONUÇLAR

Tıbbi verilerin yorumlanabilmesi için bir tıp uzmanına ihtiyaç duyulur. Fakat uzmanın verileri yorumlama doğruluğu, öznellik, verilerin karmaşıklığı, farklı uzmanlar arasındaki geniş yorum çeşitlilikleri ve uzman kişilerin fiziksel olarak yorgun olabilmeleri gibi sebeplerle sınırlı kalmaktadır. Makine öğrenmesi ve yapay zekâ teknikleri, doktorların, hastalık riskini daha hızlı ve doğru öngörebilmelerini, teşhis edebilmelerini ve zaman içinde önleyebilmelerini kolaylaştırmakta ve onlara yardımcı olmaktadır. Makine öğrenmesi ve yapay zekânın alt dalı olan derin öğrenme ise tıbbi görüntüleme alanında kullanıldığında yüksek doğruluk değerlerine ulaşabilmekte ve sağlık sektöründe gelecekteki olası uygulamalar için anahtar bir yöntem olarak görülmektedir (Razzak vd. 2018).

Bu çalışmada, MR görüntülerinde üç tür beyin tümörünü sınıflandırmak, her bir görüntüdeki tümör bölgesini tespit etmek ve bölütleme için Maskeli B-ESA yaklaşımına dayalı derin öğrenme modellerinin kullanılması amaçlanmıştır. Bu doğrultuda, iki omurgaya (ResNet-50 ve ResNet-101) dayalı ağ mimarileri ve önceden eğitilmiş iki ağırlık seti (COCO ve ImageNet görüntü veri kümelerinden üretilen) sınıflandırma performanslarına göre test edilmiştir. Görüntü veri tabanındaki her görüntü, bir tümör bölgesi ve bir tümör türü içerdiğinden, her bir Maskeli B-ESA modelinin sonucu bir sınıf etiketi olarak atanmıştır. Sonucun birden fazla sınıf veya bölgeye sahip olduğu durumlarda, maksimum puana veya maksimum IoU'ya sahip olanlardan yalnızca biri aday bölge olarak seçilmiş ve ardından sınıflandırma buna göre yapılmıştır. Test süreci sonunda COCO görüntüleri üzerinde önceden eğitilmiş ResNet-101 omurgası ile aynı görüntüler (COCO veri seti) üzerinde eğitilmiş ResNet-50 mimarisine göre daha yüksek sınıflandırma doğruluğuna (%75) ulaşılmıştır. ImageNet veri setiyle önceden eğitilmiş ResNet-50 mimarisinin ise aynı veri setiyle eğitilen (ImageNet veri seti) ResNet-101 mimarisine göre daha yüksek bir sınıflandırma doğruluğu (%87) elde ettiği görülmüştür. Önceden eğitilmiş iki ağırlık setinin (ImageNet ve COCO) sınıflandırma doğruluğu söz konusu olduğunda, ResNet-50'nin ResNet-101 ağına kıyasla daha yüksek sınıflandırma performansına sahip olduğu kaydedilmiştir. Ayrıca, ImageNet'in ağırlıkları ResNet-50 ağı ile daha iyi sonuçlar verirken, COCO veri setinden gelen ağırlıklar ResNet-101 ağı ile daha yüksek doğruluklar vermiştir. Modellerin üç tümör sınıfı için sınıflandırma hassasiyetleri şu şekilde sıralanmıştır: ResNet-50 için: M: 0.97, G: 0.92, P: 0.94; ResNet-101 için: M: 0.91, G: 0.95, P: 0.84.

Bu tez çalışmasında araştırılan modellerden en yüksek sınıflandırma performansına sahip olan iki mimarinin (ResNet-50/ImageNet ve ResNet-101/COCO), mAP, maksimum IoU veya maksimum puan değerlerine göre tespit ve bölütleme performansları ayrıca değerlendirilmiştir. Menenjiyom ve hipofiz tümörleri için benzer sınıflandırma ve bölütleme performansları elde edilirken, gliom tümörleri ise diğer tümör tipleri ile karşılaştırılabilir sınıflandırma doğruluk performansına (%73-95) rağmen nispeten daha düşük başarı oranlarında (tüm modeller için %41-73) bölütleme başarısı göstermiştir. Bunu düzeltmek için bölütleme sürecinde önerilen bölgelerin seçiminde maksimum IoU değerine sahip bölge önerileri kabul edilmiş ve bu yapıldığında daha yüksek bölütleme performansı ile birlikte mAP değerlerinde artış gözlemlenmiştir. Ayrıca kullanılan seçim yöntemi ile modellerin sınıflandırma performansı arasında herhangi bir korelasyon gözlenmemiştir. İleriki çalışmalarda Maskeli B-ESA modelinin sınıflandırma, tespit ve bölütleme başarısını arttırmak amacıyla farklı optimizasyon

algoritmaları ve ESA mimarileri üzerinde çalışmalar gerçekleştirilebilir. Ayrıca Figshare beyin tümör veri setindeki gürültülü veya net olmayan görüntüler (MRG cihaz, çekim hataları veya hasta kaynaklı olduğu düşünülen) üzerinde gürültünün azaltılması veya netliğin sağlanabilmesi için normalizasyon veya medyan filtre işlemleri uygulanarak model başarısının arttırılabileceği düşünülmektedir. Son olarak farklı sekanslarda (T1, T2 veya Flair gibi) elde edilmiş MR beyin tümör görüntülerini içeren bir veri seti ile sekansların model bölütleme ve sınıflandırmadaki etkisi de incelemeye değer bulunmaktadır.



7. KAYNAKLAR

- Abd-Ellah, M. K., Awad, A. I., Khalaf, A. A., Hamed, H. F. 2019. A review on brain tumor diagnosis from MRI images: Practical implications, key achievements, and lessons learned. *Magnetic resonance imaging*, 61: 300-318.
- Abdulla, W. 2017. Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow. *GitHub repository*.
- Akar, S. A., Ünlü, M. Z. 2014. Medikal Görüntüleme Sistemleri. In: M. H. Asyalı, S. Kara, and B. Yılmaz (Eds.). *Biyomedikal Mühendisliğinin Temelleri* ed., Vol., Nobel pp. 782.
- Aksoy, B., Halis, H. D., Salman, O. K. M. 2020. Elma Bitkisindeki Hastalıkların Yapay Zekâ Yöntemleri ile Tespiti ve Yapay Zekâ Yöntemlerinin Performanslarının Karşılaştırılması. *International Journal of Engineering and Innovative Research*, 2(3): 194-210.
- Albawi, S., Mohammed, T. A., Al-Zawi, S. 2017. *Understanding of a convolutional neural network*. Paper presented at the 2017 International Conference on Engineering and Technology (ICET).
- Alqudah, A. M., Alquraan, H., Qasmieh, I. A., Alqudah, A., Al-Sharu, W. 2020. Brain Tumor Classification Using Deep Learning Technique-A Comparison between Cropped, Uncropped, and Segmented Lesion Images with Different Sizes. *arXiv preprint arXiv:2001.08844*.
- Amin, J., Sharif, M., Gul, N., Yasmin, M., Shad, S. A. 2020. Brain tumor classification based on DWT fusion of MRI sequences using convolutional neural network. *Pattern Recognition Letters*, 129: 115-122.
- Anaraki, A. K., Ayati, M., Kazemi, F. 2019. Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. *biocybernetics and biomedical engineering*, 39(1): 63-74.
- Aslan, Z. 2019. On the use of deep learning methods on medical images. *The International Journal of Energy and Engineering Sciences*, 3(2): 1-15.
- Auger, S. D., Jacobs, B. M., Dobson, R., Marshall, C. R., Noyce, A. J. 2021. Big data, machine learning and artificial intelligence: a neurologist's guide. *Practical Neurology*, 21(1): 4-11.
- Avşar, E., Salçın, K. 2019. Detection and classification of brain tumours from MRI images using faster R-CNN. *Tehnički glasnik*, 13(4): 337-342.
- Ayturan, Y. A. 2019. Derin öğrenme ile havadaki partikül madde konsantrasyonu tahmini. KTO Karatay Üniversitesi, Konya, 57
- Badža, M. M., Barjaktarović, M. Č. 2020. Classification of brain tumors from MRI images using a convolutional neural network. *Applied Sciences*, 10(6): 1999.
- Bayram, F. 2020. Derin öğrenme tabanlı otomatik plaka tanıma. *Politeknik Dergisi*.
- Bhanothu, Y., Kamalakannan, A., Rajamanickam, G. 2020. Detection and Classification of Brain Tumor in MRI Images using Deep Convolutional Network. Paper

- presented at the 2020 6th International Conference on Advanced Computing and Communication Systems (ICACCS).
- Bharati, P., Pramanik, A. 2020. Deep Learning Techniques—R-CNN to Mask R-CNN: A Survey. In: A. K. Das, D. R. Nayak, B. Naik, S. K. Pati, & D. Pelusi (Eds.). *Computational Intelligence in Pattern Recognition* ed., Vol. 999. Springer. pp. 657-668.
- Bitar, R., Leung, G., Perng, R., Tadros, S., Moody, A. R., Sarrazin, J., Nelson, A. 2006. MR pulse sequences: what every radiologist wants to know but is afraid to ask. *Radiographics*, 26(2): 513-537.
- Cahill, J., LoBiondo-Wood, G., Bergstrom, N., Armstrong, T. 2012. Brain tumor symptoms as antecedents to uncertainty: an integrative review. *Journal of Nursing Scholarship*, 44(2): 145-155.
- Canny, J. 1986. A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*(6): 679-698.
- Chahal, P. K., Pandey, S., Goel, S. 2020. A survey on brain tumor detection techniques for MR images. *Multimedia Tools & Applications*, 79.
- Chelghoum, R., Ikhlef, A., Hameurlaine, A., Jacquir, S. 2020. *Transfer learning using convolutional neural network architectures for brain tumor classification from MRI images*. Paper presented at the IFIP International Conference on Artificial Intelligence Applications and Innovations.
- Cheng, J. 2017. brain tumor dataset. figshare. Dataset.
- Choudhary, R., Gianey, H. K. 2017. Comprehensive review on supervised machine learning algorithms. Paper presented at the 2017 International Conference on Machine Learning and Data Science (MLDS).
- Chrysikopoulos, H. S. 2009. Clinical MR imaging and physics. IX, 176.
- Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., Pringle, M. 2013. The Cancer Imaging Archive (TCIA): maintaining and operating a public information repository. *Journal of digital imaging*, 26(6): 1045-1057.
- Cockerham, K. P., Kennerdell, J. S., Maroon, J. C., Bejjani, G. K. 1998. Tumors of the meninges and related tissues: meningiomas and sarcomas. In: Walsh and Hoyt's Clinical Neuro-Ophthalmology 5th ed., Vol., Williams & Wilkins. pp. 2017-2082.
- Comelli, I., Lippi, G., Campana, V., Servadei, F., Cervellin, G. 2017. Clinical presentation and epidemiology of brain tumors firstly diagnosed in adults in the Emergency Department: a 10-year, single center retrospective study. *Annals of translational medicine*, 5(13).
- Cortes, C., Vapnik, V. 1995. Support-vector networks. *Machine learning*, 20(3): 273-297.
- Cui, S., Tseng, H. H., Pakela, J., Ten Haken, R. K., El Naqa, I. 2020. Introduction to machine and deep learning for medical physicists. *Medical physics*, 47(5): e127-e147.
- Cuşkun, Y. 2019. Beyin metazlarının derin öğrenme ile sınıflandırılması. Yüksek lisans tezi, Kocaeli Üniversitesi, Kocaeli, 92 s.

- Çürükoğlu, N. 2019. Automated Demand/Suggestion Systems. Paper presented at the 2019 4th International Conference on Computer Science and Engineering (UBMK).
- Dhruv, P., Naskar, S. 2020. Image Classification Using Convolutional Neural Network (CNN) and Recurrent Neural Network (RNN): A Review. In: D. Swain, P. K. Pattnaik, & P. K. Gupta (Eds.). Machine Learning and Information Processing ed., Vol. 1101. pp. 367-381.
- Díaz-Pernas, F. J., Martínez-Zarzuela, M., Antón-Rodríguez, M., González-Ortega, D. 2021. A Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network. Paper presented at the Healthcare.
- Doolittle, N. D. 2004. State of the science in brain tumor classification. Paper presented at the Seminars in oncology nursing.
- Dutta, A., Zisserman, A. 2019. The VIA annotation software for images, audio and video. Paper presented at the Proceedings of the 27th ACM International Conference on Multimedia.
- Fırıldak, K., Talu, M. F. 2019. Evrişimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. *Bilgisayar Bilimleri*, 4(2): 88-95.
- Girshick, R. 2015. Fast r-cnn. Paper presented at the Proceedings of the IEEE international conference on computer vision.
- Girshick, R., Donahue, J., Darrell, T., Malik, J. 2014. Rich feature hierarchies for accurate object detection and semantic segmentation. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Glorot, X., Bengio, Y. 2010. Understanding the difficulty of training deep feedforward neural networks. Paper presented at the Proceedings of the thirteenth international conference on artificial intelligence and statistics.
- Gupta, A., Dwivedi, T. 2017. A simplified overview of World Health Organization classification update of central nervous system tumors 2016. *Journal of neurosciences in rural practice*, 8(4): 629.
- Gupta, T., Gandhi, T. K., Gupta, R. K., Panigrahi, B. K. 2017. Classification of patients with tumor using MR FLAIR images. *Pattern Recognition Letters*.
- Gupta, T., Gandhi, T. K., Panigrahi, B. K. 2017. Multi-sequential MR brain image classification for tumor detection. *Journal of Intelligent & Fuzzy Systems*, 32(5): 3575-3583.
- Harish, P., Baskar, S. 2020. MRI based detection and classification of brain tumor using enhanced faster R-CNN and AlexNet model. *Materials Today: Proceedings*.
- He, K., Gkioxari, G., Dollár, P., Girshick, R. 2017. *Mask r-cnn*. Paper presented at the Proceedings of the IEEE international conference on computer vision.
- He, K., Zhang, X., Ren, S., Sun, J. 2016. Deep residual learning for image recognition. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.

- He, K. M., Gkioxari, G., Dollar, P., Girshick, R. 2017. Mask R-CNN. *2017 Ieee International Conference on Computer Vision (Iccv)*: 2980-2988.
- Hosseini, M.-P., Lu, S., Kamaraj, K., Slowikowski, A., Venkatesh, H. C. 2020. Deep learning architectures. In: W. Pedrycz & S.-M. Chen (Eds.). *Deep learning: concepts and architectures ed.*, Vol. 866. Springer. pp. 1-24.
- Hu, J., Shen, L., Sun, G. 2018. Squeeze-and-excitation networks. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q. 2017. Densely connected convolutional networks. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., Keutzer, K. 2016. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *arXiv preprint arXiv:1602.07360*.
- Ismael, S. A. A., Mohammed, A., Hefny, H. 2020. An enhanced deep learning approach for brain cancer MRI images classification using residual networks. *Artificial intelligence in medicine*, 102: 101779.
- Işın, A., Direkoğlu, C., Şah, M. 2016. Review of MRI-based brain tumor image segmentation using deep learning methods. *Procedia Computer Science*, 102: 317-324.
- Kaldera, H., Gunasekara, S. R., Dissanayake, M. 2019. Brain tumor Classification and Segmentation using Faster R-CNN. *2019 Advances in Science and Engineering Technology International Conferences (ASET)*: 1-6.
- Kaur, T., Gandhi, T. K. 2020. Deep convolutional neural networks with transfer learning for automated brain image classification. *Machine Vision and Applications*, 31(3): 1-16.
- Kavuncu, S. K. 2018. Makine öğrenmesi ve derin öğrenme: Nesne tanıma uygulaması. Kırıkkale Üniversitesi, Kırıkkale, 157 s.
- Kayaalp, K., Süzen, A. A. 2018. Derin Öğrenme ve Türkiye'deki Uygulamaları.
- Kelleher, J. D. 2019. Deep learning: MIT press.
- Khan, H. A., Jue, W., Mushtaq, M., Mushtaq, M. U. 2020. Brain tumor classification in MRI image using convolutional neural network. *Mathematical Biosciences and Engineering*, 17(5): 6203-6216.
- Khan, M. A., Ashraf, I., Alhaisoni, M., Damaševičius, R., Scherer, R., Rehman, A., Bukhari, S. A. C. 2020. Multimodal brain tumor classification using deep learning and robust feature selection: A machine learning application for radiologists. *Diagnostics*, 10(8): 565.
- Khan , M. A., Ashraf, I., Alhaisoni, M., Damaševičius, R., Scherer, R., Rehman, A., Bukhari, S. A. C. 2020. Multimodal brain tumor classification using deep learning and robust feature selection: A machine learning application for radiologists *Diagnostics*, 10(8): 565.
- Kim, P. 2017. Matlab deep learning Vol: 130. 151.

- Kızrak, M. A., Bolat, B. 2018. Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11(3): 263-286.
- Krenker, A., Beşter, J., Kos, A. 2011. Introduction to the artificial neural networks. In: K. Suzuki (Ed.). *Artificial Neural Networks: Methodological Advances and Biomedical Applications* ed., Vol., InTech. pp. 1-18.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. 2012. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25: 1097-1105.
- Kumar, J. 2013. Image Optimization in MRI. In: A. K. Gupta, V. Chowdhury, & N. Khandelwal (Eds.). *Diagnostic radiology: recent advances and applied physics in imaging* second ed., Vol. pp.
- Kumar, S. N., Fred, A. L., Padmanabhan, P., Gulyas, B., Kumar, H. A., Miriam, L. R. J. 2021. Deep Learning Algorithms in Medical Image Processing for Cancer Diagnosis: Overview, Challenges and Future. In: U. Kose & J. Alzubi (Eds.). *Deep Learning for Cancer Diagnosis* ed., Vol. 908. Springer. pp. 37-66.
- Lahmiri, S. 2017. Glioma detection based on multi-fractal features of segmented brain MRI by particle swarm optimization techniques. *Biomedical Signal Processing and Control*, 31: 148-155.
- Larjavaara, S., Mäntylä, R., Salminen, T., Haapasalo, H., Raitanen, J., Jääskeläinen, J., Auvinen, A. 2007. Incidence of gliomas by anatomic location. *Neuro-oncology*, 9(3): 319-325.
- LeCun, Y., Boser, B. E., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. E., Jackel, L. D. 1990. *Handwritten digit recognition with a back-propagation network*. Paper presented at the Advances in neural information processing systems.
- LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11): 2278-2324.
- Lee, J.-G., Jun, S., Cho, Y.-W., Lee, H., Kim, G. B., Seo, J. B., Kim, N. 2017. Deep learning in medical imaging: general overview. *Korean journal of radiology*, 18(4): 570.
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Zitnick, C. L. 2014. *Microsoft coco: Common objects in context*. Paper presented at the European conference on computer vision.
- Liu, J., Li, M., Wang, J., Wu, F., Liu, T., Pan, Y. 2014. A survey of MRI-based brain tumor segmentation methods. *Tsinghua science and technology*, 19(6): 578-595.
- Liu, S., Deng, W. 2015. Very deep convolutional neural network based image classification using small training sample size. Paper presented at the 2015 3rd IAPR Asian conference on pattern recognition (ACPR).
- Ludwig, P. E., Reddy, V., Varacallo, M. 2017. Neuroanatomy, central nervous system (CNS).

- Maltarollo, V. G., Honório, K. M., da Silva, A. B. F. 2013. Applications of artificial neural networks in chemical problems. In: K. Suzuki (Ed.). Artificial neural networks-architectures and applications ed., Vol. pp. 203-223.
- Maravilla, K. R., Sory, W. C. 1986. Magnetic resonance imaging of brain tumors. *Semin Neurol*, 6(1): 33-42.
- Masood, M., Nazir, T., Nawaz, M., Javed, A., Iqbal, M., Mehmood, A. 2020. Brain Tumor Localization and Segmentation using Mask RCNN.
- Masood, M., Nazir, T., Nawaz, M., Mehmood, A., Rashid, J., Kwon, H.-Y., Hussain, A. 2021. A Novel Deep Learning Method for Recognition and Classification of Brain Tumors from MRI Images. *Diagnostics*, 11(5): 744.
- McNeill, K. A. 2016. Epidemiology of brain tumors. *Neurologic clinics*, 34(4): 981-998.
- Mehrotra, R., Ansari, M., Agrawal, R., Anand, R. 2020. A Transfer Learning approach for AI-based classification of brain tumors. *Machine Learning with Applications*, 2: 100003.
- Metlek, S., Kayaalp, K. 2020. Otistik Spektrum Bozukluğunun Makine Öğrenme Algoritmaları ile Tespiti. *Zeki Sistemler Teori ve Uygulamaları Dergisi*, 3(2): 60-68.
- Minniti, G., Romano, A., Scaringi, C., Bozzao, A. 2019. Imaging in Neuro-Oncology. In: M. Bartolo, R. Soffietti, and M. Klein (Eds.). *Neurorehabilitation in Neuro-Oncology* 1 ed., Vol. pp.
- Mohammed, B. A., Al-Ani, M. S. 2021. An efficient approach to diagnose brain tumors through deep CNN *Mathematical Biosciences and Engineering*, 18(1): 851-867.
- Mohindra, N., Neyaz, Z. 2015. Magnetic resonance sequences: Practical neurological applications. *Neurology India*, 63(2): 241.
- Muhammad, K., Khan, S., Del Ser, J., de Albuquerque, V. H. C. 2020. Deep learning for multigrade brain tumor classification in smart healthcare systems: A prospective survey. *IEEE Transactions on Neural Networks and Learning Systems*.
- Nayak, D. R., Dash, R., Majhi, B. 2016. Brain MR image classification using two-dimensional discrete wavelet transform and AdaBoost with random forests. *Neurocomputing*, 177: 188-197.
- Nilsson, M., Englund, E., Szczepankiewicz, F., van Westen, D., Sundgren, P. C. 2018. Imaging brain tumour microstructure. *Neuroimage*, 182: 232-250.
- Noreen, N., Palaniappan, S., Qayyum, A., Ahmad, I., Imran, M., Shoaib, M. 2020. A Deep Learning Model Based on Concatenation Approach for the Diagnosis of Brain Tumor. *IEEE Access*, 8: 55135-55144.
- Öziç, M. Ü. 2013. MR görüntülerinde alzheimer hastalığının özniteliklerinin belirlenmesi. Selçuk Üniversitesi Konya,
- Öztürk, K., Şahin, M. E. 2018. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2): 25-36.

- Patra, A., Janu, A., Sahu, A. 2019. MR Imaging in Neurocritical Care. *Indian journal of critical care medicine : peer-reviewed, official publication of Indian Society of Critical Care Medicine*, 23(Suppl 2): S104-S114.
- Polat, Ö., Güngen, C. 2021. Classification of brain tumors from MR images using deep transfer learning. *The Journal of Supercomputing*: 1-17.
- Pruis, I. J., van Dongen, G. A. M. S., Veldhuijzen van Zanten, S. E. M. 2020. The added value of diagnostic and theranostic PET imaging for the treatment of CNS tumors. *International journal of molecular sciences*, 21(3): 1029.
- Ram, S., Gupta, A. 2020. Glioma Tumor Detection Through Faster Region-Based Convolutional Neural Networks Using Transfer Learning. *European Journal of Molecular & Clinical Medicine*, 7(2): 4789-4815.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., Yang, G.-Z. 2016. Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1): 4-21.
- Razzak, M. I., Naz, S., Zaib, A. 2018. Deep learning for medical image processing: Overview, challenges and the future. *Classification in BioApps*: 323-350.
- 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, S., He, K., Girshick, R., Sun, J. 2016. Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE Transactions on pattern analysis and machine intelligence*, 39(6): 1137-1149.
- Revett, K. 2011. An introduction to magnetic resonance imaging: from image acquisition to clinical diagnosis. In: H. Kwasnicka and L. C. Jain (Eds.). *Innovations in intelligent image analysis ed., Vol., Springer*. pp. 127-161.
- Reynoso-Noverón, N., Mohar-Betancourt, A., Ortiz-Rafael, J. 2021. Epidemiology of Brain Tumors. In: *Principles of Neuro-Oncology ed., Vol., Springer*. pp. 15-25.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Bernstein, M. 2015. Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115(3): 211-252.
- Russakovsky, O., Fei-Fei, L. 2010. Attribute learning in large-scale datasets. Paper presented at the European Conference on Computer Vision.
- Rydning, D. R. J. G. J. 2018. The digitization of the world from edge to core. *Framingham: International Data Corporation*.
- Saranya, C., Priya, J. G., Jayalakshmi, P., Pavithra, E. H. 2021. Brain tumor identification using deep learning. *Materials Today: Proceedings*.
- Schillaci, O., Filippi, L., Manni, C., Santoni, R. 2007. Single-photon emission computed tomography/computed tomography in brain tumors. Paper presented at the Seminars in nuclear medicine.
- Selvapandian, A., Athilingam, R., Sivakumar, P. 2020. Performance analysis of Glioma brain tumor detection and segmentation using image registration technique. *Materials Today: Proceedings*.

- Shier, D., Butler, J., Lewis, R. 2018. Hole's essentials of human anatomy & physiology: McGraw-Hill Education.
- Shin, H.-C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., Summers, R. M. 2017. Three Aspects on Using Convolutional Neural Networks for Computer-Aided Detection in Medical Imaging. In: L. Lu, Y. Zheng, G. Carneiro, and L. Yang (Eds.). Deep Learning and Convolutional Neural Networks for Medical Image Computing ed., Vol., Springer. pp. 113-136.
- Simonyan, K., Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Sprawls, P. 2000. Magnetic resonance imaging: principles, methods, and techniques. Madison, Wisconsin: Medical Physics Publishing Corporation.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. 2014. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1): 1929-1958.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. 2015. Going deeper with convolutions. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. 2016. Rethinking the inception architecture for computer vision. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Talo, M., Baloglu, U. B., Yıldırım, Ö., Acharya, U. R. 2019. Application of deep transfer learning for automated brain abnormality classification using MR images. *Cognitive Systems Research*, 54: 176-188.
- Valverde, J. M., Imani, V., Abdollahzadeh, A., De Feo, R., Prakash, M., Ciszek, R., Tohka, J. 2021. Transfer Learning in Magnetic Resonance Brain Imaging: A Systematic Review. *Journal of Imaging*, 7(4): 66.
- Wang, W., Liang, D., Chen, Q., Iwamoto, Y., Han, X.-H., Zhang, Q., Chen, Y.-W. 2020. Medical image classification using deep learning. In: Y.-W. Chen & L. C. Jain (Eds.). Deep Learning in Healthcare ed., Vol. 171. Springer. pp. 33-51.
- Wani, M. A., Bhat, F. A., Afzal, S., Khan, A. I. 2020. Advances in deep learning: Springer.
- Westbrook, C., Talbot, J. 2018. MRI in Practice Fifth ed.: John Wiley & Sons.
- Xu, S., Liu, C., Zong, Y., Chen, S., Lu, Y., Yang, L., Liu, Y. 2019. An early diagnosis of oral cancer based on three-dimensional convolutional neural networks. *IEEE Access*, 7: 158603-158611.
- Yadav, G., Maheshwari, S., Agarwal, A. 2014. Contrast limited adaptive histogram equalization based enhancement for real time video system. Paper presented at the 2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI).
- Yamashita, R., Nishio, M., Do, R. K. G., Togashi, K. 2018. Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, 9(4): 611-629.

- Yan, L. C., Yoshua, B., Geoffrey, H. 2015. Deep learning. *nature*, 521(7553): 436-444.
- Yapıcıer, Ö. 2020. Pathology, Epidemiology, and WHO Classification of Brain Tumors. In: Y. Özsunar and U. Şenol (Eds.). Atlas of Clinical Cases on Brain Tumor Imaging ed., Vol., Springer. pp.
- Zhang, J., Traylor, K. S., Mountz, J. M. 2020. PET and SPECT Imaging of Brain Tumors. Paper presented at the Seminars in Ultrasound, CT and MRI.
- Zhang , X.-D. 2020. A Matrix Algebra Approach to Artificial Intelligence: Springer.
- Zou, J., Han, Y., So, S.-S. 2008. Overview of artificial neural networks. In: D. J. Livingstone (Ed.). Artificial Neural Networks ed., Vol., Humana Press. pp. 15-23.
- Anonymous 1: Cancer Stat Facts: Brain and Other Nervous System Cancer. <https://seer.cancer.gov/statfacts/html/brain.html> [Son erişim tarihi: 01.01.2021].
- Anonymous 2: <http://blog.braintumor.org/files/public-docs/frankly-speaking-about-cancer-brain-tumors.pdf> [Son erişim tarihi: 01.01.2021].
- Anonymous 3: <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection> [Son erişim tarihi: 01.01.2021]. (<https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection>)
- Anonymous 4: Tzutalin, “LabelImg. Git code,” 2015.
- Anonymous 5: A. Hoofring, “Brain and Nearby Structures,” 2007. <https://visualsonline.cancer.gov/details.cfm?imageid=4279> [Son erişim tarihi: 16.02.2021].
- Anonymous 6: <https://www.cancer.org/content/dam/CRC/PDF/Public/8567.00.pdf> [Son erişim tarihi: 17.02.2021].
- Anonymous 7: G. Kisby and Y. Weerakkody, “SPECT vs PET,” Radiopaedia, 2020. <https://radiopaedia.org/articles/spect-vs-pet> [Son erişim tarihi: 17.02.2021].
- Anonymous 8: Y. Baba and J. Jones, “T1 weighted image,” Radiopaedia. <https://radiopaedia.org/articles/t1-weighted-image> [Son erişim tarihi: 17.02.2021].
- Anonymous 9: S. Vadera and J. Jones, “T2 weighted image,” Radiopaedia. <https://radiopaedia.org/articles/t2-weighted-image> [Son erişim tarihi: 17.02.2021].
- Anonymous 10: MRI sequence. https://en.wikipedia.org/wiki/MRI_sequence [Son erişim tarihi: 01.01.2021]
- Anonymous 11: Deng, F. and Niknejad, M. T. Fluid attenuated inversion recovery <https://radiopaedia.org/articles/fluid-attenuated-inversion-recovery> [Son erişim tarihi: 01.01.2021]
- Anonymous 12: Mittal, A. 2019. Instance segmentation using Mask R-CNN <https://aditi-mittal.medium.com/instance-segmentation-using-mask-r-cnn-7f77bdd46abd> [Son erişim tarihi: 17.02.2021]
- Anonymous 13: Gupta, D. S. 2020. Fundamentals of Deep Learning – Activation Functions and When to Use Them?

- <https://www.analyticsvidhya.com/blog/2020/01/fundamentals-deep-learning-activation-functions-when-to-use-them/> [Son erişim tarihi: 17.02.2021]
- Anonymous 14: Sharma, S. 2017. Epoch vs Batch Size vs Iterations <https://towardsdatascience.com/epoch-vs-iterations-vs-batch-size-4dfb9c7ce9c9> [Son erişim tarihi: 19.05.2021]
- Anonymous 15: Brownlee, J. 2019. Understand the Impact of Learning Rate on Neural Network Performance <https://machinelearningmastery.com/understand-the-dynamics-of-learning-rate-on-deep-learning-neural-networks/> [Son erişim tarihi: 19.05.2021]
- Anonymous 16: Zulkifli, H. 2018. Understanding Learning Rates and How It Improves Performance in Deep Learning <https://towardsdatascience.com/understanding-learning-rates-and-how-it-improves-performance-in-deep-learning-d0d4059c1c10> [Son erişim tarihi: 19.05.2021]
- Anonymous 17: Khandelwal, R. 2018. Machine learning : Gradient Descent <https://arshren.medium.com/gradient-descent-5a13f385d403> [Son erişim tarihi: 20.05.2021]
- Anonymous 18: Kasirajan, A. 2020. Optimization Techniques popularly used in Deep Learning <https://medium.com/@minions.k/optimization-techniques-popularly-used-in-deep-learning-3c219ec8e0cc> [Son erişim tarihi: 19.05.2021]
- Anonymous 19: Doshi, S. 2019. Various Optimization Algorithms For Training Neural Network <https://towardsdatascience.com/optimizers-for-training-neural-network-59450d71caf6> [Son erişim tarihi: 19.05.2021]
- Anonymous 20: What is NumPy? <https://numpy.org/doc/stable/user/whatisnumpy.html> [Son erişim tarihi: 21.05.2021]
- Anonymous 21: Yegulalp, S. 2019. What is TensorFlow? The machine learning library explained <https://www.infoworld.com/article/3278008/what-is-tensorflow-the-machine-learning-library-explained.html> [Son erişim tarihi: 21.05.2021]
- Anonymous 22: About Keras. <https://keras.io/about/> [Son erişim tarihi: 21.05.2021]
- Anonim 1: Çarkacı, N. 2018. Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper-parametreler <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> [Son erişim tarihi: 19.05.2021]
- Anonim 2: Soytürk, Z. Python nedir? <https://www.mediaticlick.com.tr/tr/blog/python-nedir> [Son erişim tarihi: 21.05.2021]

ÖZGEÇMİŞ

MERVE KÖRDEMİR

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2017-2021	Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Antalya
Lisans	Kocaeli Üniversitesi
2013-2017	Teknoloji Fakültesi, Biyomedikal Mühendisliği Bölümü, Kocaeli

MESLEKİ VE İDARİ GÖREVLER

Öğretmen	
2017-2021	Konyaaltı Bahtılı Mesleki ve Teknik Anadolu Lisesi, Antalya